



20



**НАЦИОНАЛЬНАЯ
КОНФЕРЕНЦИЯ
ПО ИСКУССТВЕННОМУ
ИНТЕЛЛЕКТУ
С МЕЖДУНАРОДНЫМ
УЧАСТИЕМ**



КИИ-2022



ТРУДЫ КОНФЕРЕНЦИИ

Том 2

21-23 декабря 2022 г.
Москва

20

Министерство науки
и высшего образования РФ

Российская ассоциация
искусственного интеллекта

Федеральный
исследовательский центр
«Информатика и
управление» РАН

Национальный
исследовательский
университет «МЭИ»

НАЦИОНАЛЬНАЯ КОНФЕРЕНЦИЯ ПО ИСКУССТВЕННОМУ ИНТЕЛЛЕКТУ С МЕЖДУНАРОДНЫМ УЧАСТИЕМ

КИИ-2022

ТРУДЫ КОНФЕРЕНЦИИ

Том 2

21–23 декабря 2022 г.
Москва, НИУ «МЭИ»

*К 90-летию со дня рождения
Дмитрия Александровича Поспелова*

Москва
Издательство МЭИ
2022

УДК 004.8+004.89+004.82+004.032.26(045)

ББК 32.813

Д 22

Организаторы конференции:

*Российская ассоциация искусственного интеллекта
Федеральный исследовательский центр «Информатика и управление» РАН
Национальный исследовательский университет «МЭИ»*

Рецензенты: академик РАН, ИПУ РАН С.Н. Васильев,
д.т.н., доц., ФИЦ ИУ РАН В.Н. Захаров

Д 22 Двадцатая Национальная конференция по искусственному интеллекту с международным участием, КИИ-2022 (Москва, 21–23 декабря 2022 г.). Труды конференции. В 2 т. Т. 2. – М.: Издательство МЭИ, 2022. – 464 с.

ISBN 978-5-7046-2735-7

ISBN 978-5-7046-2737-1 (Т. 2)

Юбилейная двадцатая конференция КИИ-2022 проходит в год 90-летия со дня рождения Дмитрия Александровича Поспелова – выдающегося отечественного ученого в области искусственного интеллекта, одного из главных организаторов этого направления исследований и разработок в России.

Во втором томе трудов публикуются доклады участников конференции, представленные на следующих секциях:

Секция 3 «Нейросетевые, нечеткие методы. Мягкие измерения и вычисления»,

Секция 4 «Прикладные интеллектуальные системы. Инструментальные средства построения интеллектуальных систем»,

Секция 5 «Интеллектуальные системы поддержки принятия решений и управления».


**УДК 004.8+004.89+004.82+004.032.26(045)
ББК 32.813**

*Материалы печатаются в авторской редакции методом
прямого репродуцирования с авторских оригиналов*

ISBN 978-5-7046-2735-7

ISBN 978-5-7046-2737-1 (Т. 2)

© Национальный исследовательский университет «МЭИ», 2022



*Дмитрий Александрович Поспелов
(1932–2019 гг.)*

СОПРЕДСЕДАТЕЛИ КОНФЕРЕНЦИИ

Соколов И.А., акад. РАН, ФИЦ ИУ РАН, Москва

Роголёв Н.Д., д.т.н., проф., НИУ «МЭИ», Москва

ПРОГРАММНЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель Программного комитета

Кобринский Б.А., д.м.н., проф., ФИЦ ИУ РАН, Москва

Заместители председателя Программного комитета

Еремеев А.П., д.т.н., проф., НИУ «МЭИ», Москва

Забейало М.И., д.ф.-м.н., проф., ФИЦ ИУ РАН, Москва

Ответственный секретарь Программного комитета

Виноградов Д.В., д.ф.-м.н., ФИЦ ИУ РАН, Москва

Члены программного комитета

Аверкин А.Н., к.ф.-м.н., доц., ФИЦ ИУ РАН, Москва

Алиев Р.А., д.т.н., проф., АЗГНА, Азербайджан, Баку

Афанасьева Т.В., д.т.н., РЭУ им. Г.В. Плеханова, Москва

Базенков Н.И., к.т.н., с.н.с. ИПУ РАН, Москва

Борисов В.В., д.т.н., проф., филиал НИУ «МЭИ», Смоленск

Васильев С.Н., акад. РАН, ИПУ РАН, г. Москва

Гаврилова Т.А., д.т.н., проф., СПбГУ, Санкт-Петербург

Городецкий В.И., д.т.н., проф., АО «Эврика», Санкт-Петербург

Грибова В.В., член-корр. РАН, ИАПУ ДВО РАН, Владивосток

Драгунов В.К., д.т.н., проф., НИУ «МЭИ», Москва

Добрынин Д.А., к.т.н., с.н.с. ФИЦ ИУ РАН, Москва

Жилиякова Л.Ю., д.ф.-м.н., в.н.с. ИПУ РАН, Москва

Загоруйко Ю.А., к.т.н., ИСИ СО РАН, Новосибирск

Захаров В.Н., д.т.н., доц., ФИЦ ИУ РАН, Москва

Зацаринный А.А., д.т.н., доц., ФИЦ ИУ РАН, Москва

Ковалев С.М., д.т.н., проф., РГУПС, Ростов-на-Дону

Колесников А.В., д.т.н., проф., БФУ, Калининград

Колоденкова А.Е., д.т.н., доц., СамГТУ, Самара

Котенко И.В., д.т.н., проф., СПИИРАН, СПб

Кузнецов О.П., д.т.н., проф., ИПУ РАН, Москва

Кузнецов С.О., д.ф.-м.н., проф., НИУ ВШЭ, Москва

Кулинич А.А., к.т.н., доц., ИПУ РАН, Москва

Курейчик В.В., д.т.н., проф., ЮФУ, Ростов-на-Дону

Лебедев О.Б., д.т.н., доц., ИКТИБ ЮФУ, Таганрог

Лукашевич Н.В., д.т.н., проф. НИВЦ МГУ, Москва

Мисник А.Е., к.т.н., доц., БРУ, Республика Беларусь, Могилев

Михеенкова М.А., д.т.н., проф., ФИЦ ИУ РАН, Москва

Пальчунов Д.Е., д.ф.-м.н., доц., ИМ СО РАН, Новосибирск
Паллох Б.В., д.т.н., проф., ТвГТУ, Тверь
Панов А.И., к.ф.-м.н., доц., ФИЦ ИУ РАН, Москва
Редько В.Г., д.ф.-м.н., проф., НИИСИ РАН, Москва
Ройзензон Г.В., к.т.н., доц., ФИЦ ИУ РАН, Москва
Рыбина Г.В., д.т.н., проф., НИЯУ МИФИ, Москва
Семенов Н.А., д.т.н., проф. ТвГТУ, Москва
Смирнов И.В., к.ф.-м.н., доц., ФИЦ ИУ РАН, Москва
Стефанюк В.Л., д.т.н., проф., ИППИ РАН, Москва
Сулейманов Д.Ш., акад. АН РТ, ИПС АН РТ, Казань
Тельнов Ю.Ф., д.э.н., проф., РЭУ, Москва
Федунов Б.Е., д.т.н., проф., ГосНИИ АС, Москва
Финн В.К., д.т.н., проф., ФИЦ ИУ РАН, г. Москва
Фоминых И.Б., д.т.н., проф., НИУ «МЭИ», г. Москва
Харламов А.А., д.т.н., проф., ИВНД и НФ РАН, Москва
Хачумов В.М., д.т.н., проф., ФИЦ ИУ РАН, Москва
Хорошевский В.Ф., д.т.н., проф., ФИЦ ИУ РАН, Москва
Юдин Д.А. к.т.н., с.н.с. МФТИ, Москва
Юсупбеков Н.Р., акад. АН РУз, ТашГТУ, Узбекистан, Ташкент
Яковлев К.С., к.ф.-м.н., ФИЦ ИУ РАН, Москва
Ярушкина Н.Г., д.т.н., проф., УлГТУ, Ульяновск

ОРГАНИЗАЦИОННЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель Организационного комитета

Борисов В.В., д.т.н., проф., филиал НИУ «МЭИ», г. Смоленск

Заместитель председателя Организационного комитета

Бобряков А.В., д.т.н., проф., НИУ «МЭИ», г. Москва

Члены организационного комитета

Варшавский П.Р., к.т.н., доц., НИУ «МЭИ», г. Москва

Вишняков С.В., к.т.н., доц. НИУ «МЭИ», г. Москва

Гладков Л.А., к.т.н., доц., ИКТИБ ЮФУ, г. Таганрог

Луферов В.С., к.т.н., филиал НИУ «МЭИ», г. Смоленск

Синявский Ю.В., к.т.н., доц., филиал НИУ «МЭИ», г. Смоленск

Солопов Р.В., к.т.н., доц., филиал НИУ «МЭИ», г. Смоленск

ИНФОРМАЦИОННАЯ ПОДДЕРЖКА КОНФЕРЕНЦИИ

ООО «Лаборатория информационных технологий» (Россия, Смоленск)

ПРЕДИСЛОВИЕ

Юбилейная XX Национальная конференция по искусственному интеллекту с международным участием (КИИ-2022) своими истоками восходит к первой КИИ в 1988 году и продолжает традицию советских (российских) конференций, у основания которых стоял Дмитрий Александрович Поспелов – выдающийся отечественный ученый в области искусственного интеллекта, 90-летие со дня рождения которого мы отмечаем в 2022 году.

Организаторами конференции являются Российская ассоциация искусственного интеллекта, Федеральный исследовательский центр «Информатика и управление» РАН, Национальный исследовательский университет «МЭИ».

Тематика конференции охватывает следующие основные направления искусственного интеллекта: инженерия знаний; когнитивные исследования; интеллектуальный анализ текстов; интеллектуальный анализ данных; объяснимый искусственный интеллект; нейросетевые и нечеткие методы, мягкие измерения и вычисления; интеллектуальные системы поддержки принятия решений и управления; прикладные интеллектуальные системы и инструментальные средства построения интеллектуальных систем.

На конференцию представлены пленарные доклады видных ученых и специалистов в области искусственного интеллекта. Из поданных на конференцию 89 секционных докладов Программным комитетом после рецензирования отображены 59 докладов.

В конференции принимают участие более 150 ученых, исследователей и специалистов из академических институтов, университетов, отраслевых институтов и организаций Москвы, Санкт-Петербурга, Белгорода, Владивостока, Иркутска, Казани, Калининграда, Новосибирска, Ростова-на-Дону, Самары, Смоленска, Таганрога, Твери, Ульяновска, Уфы, Могилёва (Республика Беларусь).

Мы посвящаем это издание памяти наших дорогих коллег – Дмитрия Александровича Поспелова и многолетнего члена Научного совета Российской ассоциации искусственного интеллекта Делира Гасемовича Лахути, ушедшего из жизни в этом году.

Делир Гасемович Лахути (1934–2022 гг.) – доктор технических наук, профессор, выдающийся специалист в области информатики, философии, филологии. Круг его научных интересов включал в себя автоматический анализ текстов на естественном языке и информационно-поисковые системы полнотекстовых баз данных. Он – автор уникальных работ о проблемах перевода философских текстов. Его книга «Вдумываясь в текст» – оригинальное исследование точной филологии. Человек выдающейся эрудиции, Д.Г. Лахути был одним из лучших переводчиков научных текстов, чьи переводы книг Л. Витгенштейна, У.Р. Эшби, Ч.С. Пирса, К.Р. Поппера считаются классическими.

Выражаем искреннюю благодарность Д.В. Виноградову, В.С. Луферову, Н.В. Ярошевич, Ю.В. Синявскому, Р.В. Солопову, Е.В. Вельмакиной за активное участие в подготовке трудов к печати, в организации и проведении конференции.

Программный и Организационный комитеты КИИ-2022

СЕКЦИЯ 3

**НЕЙРОСЕТЕВЫЕ, НЕЧЕТКИЕ
МЕТОДЫ.
МЯГКИЕ ИЗМЕРЕНИЯ
И ВЫЧИСЛЕНИЯ**

УДК 004.386

**СВОЙСТВА ПАМЯТИ СИСТЕМЫ РЕЗЕРВУАРНЫХ
ВЫЧИСЛЕНИЙ ПРИ ИЗМЕНЕНИИ ВРЕМЕНИ ВВОДА
СИМВОЛОВ***

Е.А. Викторов (*evviktor@gmail.com*)

Г.О. Даниленко (*danilenko.gleb98@gmail.com*)

А.В. Ковалев (*avkovalev@itmo.ru*)

Университет ИТМО, Санкт-Петербург

В работе представлены результаты исследования влияния времени ввода данных на емкость памяти системы резервуарных вычислений на основе полупроводникового лазера с оптоэлектронной обратной связью с фильтрацией. Продемонстрирован эффект снижения емкости памяти при совпадении периода ввода данных с периодами собственных колебаний системы, показано изменение резонансных провалов емкости памяти при изменении полосы пропускания обратной связи.

Ключевые слова: резервуарные вычисления, емкость памяти, резонанс, фильтрация, лазер, динамические системы с задержкой.

* Работа выполнена при финансовой поддержке гранта Президента РФ МК-1788.2022.1.2 (соглашение № 075-15-2022-686).

Введение

Резервуарные вычисления (РВ) – это один из подходов к проектированию и обучению рекуррентных нейронных сетей. Особенностью архитектуры РВ является нелинейная обработка данных в резервуаре, который состоит из нелинейных узлов, связанных некоторым (в т.ч., произвольным) образом, и обладает сложным откликом на входящее возмущение [Larger и др., 2017], [Röhm, 2019].

Особенности архитектуры РВ способствуют повышению производительности и эффективности системы при решении задач классификации, распознавания речи и предсказания временных рядов по сравнению с другими рекуррентными сетями за счет возможности аналоговой аппаратной реализации и упрощенного процесса обучения (обучению подвергается только выходной слой системы). Проектирование систем РВ с использованием оптических устройств, например, лазеров, обеспечивает большую скорость обработки данных и вычислений [Chembo, 2020] и энергоэффективность [Argyris и др., 2018].

В настоящей работе в качестве резервуара используется лазерный диод с запаздывающей по времени оптоэлектронной обратной связью. Данный резервуар на основе единственного нелинейного узла с запаздывающей обратной связью обладает фазовым пространством высокой размерности (и соответствующей ему рекуррентной сети) [Lugnan и др., 2020], что позволяет получить сложный динамический отклик на входное воздействие и хорошо различимые отклики для отличающихся входных данных. Для реализации системы РВ на основе такой архитектуры используется подход мультиплексирования по времени, при котором разделяемые во времени виртуальные узлы распределены в контуре обратной связи через одинаковые временные интервалы.

В данной работе демонстрируется влияние времени ввода данных в систему РВ на емкость ее памяти, в частности, отмечается резкое уменьшение емкости памяти в случае совпадения времени ввода и периода собственных колебаний резервуара. Также, показано улучшение емкости памяти в случае изменения полосы пропускания петли обратной связи.

1. Модель системы РВ на основе полупроводникового лазера с обратной оптоэлектронной связью с полосовой фильтрацией

Лазер с оптоэлектронной обратной связью, которая содержит фильтры низких и высоких частот, описывается системой дифференциальных уравнений с запаздывающим аргументом, которая базируется на модели, представленной в [Dmitriev и др., 2020], и дополнена фильтром низких частот:

$$\dot{I}(t) = 2N_g(t)I(t), \quad (1.1)$$

$$\dot{I}_{FH}(t) = -\tau_H^{-1}I_{FH}(t) + 2N_g(t)I(t), \quad (1.2)$$

$$\dot{I}_{FL}(t) = \tau_L^{-1}(I_{FH}(t) - I_{FL}(t)), \quad (1.3)$$

$$\varepsilon^{-1}\dot{N}_g(t) = P(t) + \eta I_{FL}(t - \tau) - N_g(t) - (1 + 2N_g(t))I(t), \quad (1.4)$$

где $t = t'/\tau_p$, t' – время, τ_p – время жизни фотона в резонаторе, $I(t)$ – нормированная интенсивность лазерного излучения внутри резонатора, $N_g(t)$ – нормированная инверсия населенности активной среды, $I_{FH}(t)$ – интенсивность сигнала после фильтра высоких частот, τ_H – величина, обратная частоте среза фильтра высоких частот, $I_{FL}(t)$ – интенсивность сигнала после фильтра низких частот, τ_L – величина, обратная частоте среза фильтра низких частот, ε – отношение времени жизни фотонов в резонаторе ко времени жизни носителей заряда в активной среде, $P(t)$ – параметр накачки, η – сила обратной связи, τ – время задержки обратной связи. Точка над переменными обозначает производную по t .

Ввод входного сигнала осуществляется изменением тока накачки, причем амплитуда входного сигнала изменяется в промежутке $[0, 1]$. Одно значение входных данных (символ) является постоянным в течение интервала времени ввода данных в систему τ_{sym} , который, как правило, принимается равным времени запаздывания обратной связи. Для формирования сигнала модуляции используется так называемая маска, которая задается случайным образом. Маска представляет собой сигнал, который ступенчато изменяется после истечения интервала θ , определяемого как

$$\theta = \frac{\tau_{sym}}{N}, \quad (1.5)$$

где N – количество виртуальных узлов. Ступенчатые уровни маски являются случайными значениями из интервала $[-1, 1]$, а ее длительность равна τ_{sym} . Маска является фиксированной для каждого входного символа и сигнал модуляции $M(t)$ формируется перемножением маски на амплитуду каждого входного символа.

Сигнал, подаваемый на лазерный диод, является суммой постоянного тока накачки и переменного входного сигнала с определенной амплитудой модуляции ξ . Таким образом, параметр накачки либо увеличивается, либо уменьшается на значение произведения амплитуды модуляции и переменного входного сигнала, лежащего в диапазоне $[-1, 1]$.

$$P(t) = P(1 + \xi \cdot M(t)), \quad (1.6)$$

где P – постоянное значение параметра накачки.

Предлагаемая схема системы, описываемой уравнениями (1.1)–(1.4), представлена на рис. 1.




Рис. 1. Условная схема исследуемой системы РВ на основе полупроводникового лазера с оптоэлектронной обратной связью, подверженной полосовой фильтрации. ЛД – лазерный диод, Усил – усилитель, ФНЧ – фильтр низких частот, ФВЧ – фильтр высоких частот, ФД – фотодетектор.

Фиксированные параметры для моделирования: $\varepsilon = 0.1$, $\tau_H = 2000$, $\tau = 1000$, $N = 48$, $\xi = 0.1$.

Ключевыми параметрами исследования являются частота среза фильтра низких частот $1/\tau_L$ и время ввода одного значения данных в систему РВ $\tau_{\text{сум}}$. Моделирование выполнялось для трех значений временной постоянной $\tau_L = 1, 7.5$ и 10 . Значения t, τ, τ_H, τ_L и $\tau_{\text{сум}}$ нормированы на время жизни фотона в резонаторе $\tau_p = 100$ пс.

2. Емкость памяти

Емкость памяти (*англ.* memory capacity) введена в [Jaeger, 2002] как характеристика способности системы РВ восстанавливать входные данные, введенные на предыдущих итерациях ввода.

Согласно работе [Dmitriev и др., 2020] наилучшая производительность рассматриваемой системы достигается вблизи границы бифуркации Андронова-Хопфа. Для определения границ бифуркации Андронова-Хопфа и выбора диапазонов параметров для моделирования системы РВ был проведен линейный анализ устойчивости. Полученные границы бифуркаций изображены на рис. 2. Также, из линейного анализа устойчивости были определены периоды собственных колебаний системы, соответствующие обратным величинам мнимых частей собственных значений. Собственные значения для положительной и отрицательной обратной связи не совпадают, поскольку частоты для положительной обратной связи близки к значениям K/τ , а для отрицательной близки к значениям $K/\tau + 1/(2\tau)$, где K – целое число.

Емкость памяти рассчитывается по формуле [Jaeger, 2002], [Appeltant, 2012].

$$MC = \sum_{m=1}^{\infty} \frac{cov^2(O_i, S_{i-m})}{\sigma^2(O_i)\sigma^2(S_i)}, \quad (2.1)$$

где cov – ковариация, O_i – выходной сигнал, S_{i-m} – входной сигнал, σ^2 – дисперсия.

Результаты расчета емкости памяти представлены на рис. 2. Границы бифуркации Андронова – Хопфа для каждого значения τ_L показаны на графиках белыми линиями.




Рис. 2. Двумерные диаграммы емкости памяти в плоскости параметров силы обратной связи и параметра накачки (η, P). Сверху вниз τ_L : 1, 7.5 и 10.

Белые линии показывают границы бифуркаций Андронова-Хопфа

В результате расчета емкости памяти для трех значений τ_L , указанных выше, получены следующие результаты: с ростом τ_L емкость памяти сначала увеличивается, после чего уменьшается, но все еще превышает значения MC для $\tau_L = 1$. Наибольшие значения наблюдаются вблизи границы бифуркации Андронова-Хопфа. Максимальное значение емкости памяти получено для $\tau_L = 7.5$ при отрицательной обратной связи и равняется $MC = 40$. Аналогично работе [Dmitriev и др., 2020] емкость памяти асимметрична относительно знака обратной связи, большие значения получаются для отрицательной обратной связи для каждого значения τ_L .

3. Влияние выбора времени ввода данных в систему

Для получения максимальной емкости памяти кроме близости к границам бифуркации должно также выполняться как минимум еще одно условие. Из работы [Gonon и др., 2020] следует, что резервуар должен работать вне резонансного состояния, то есть следует избегать совпадения времени ввода одного символа τ_{sym} и периода собственных колебаний системы, что приводит к так называемому резонансному состоянию и уменьшению емкости памяти [Köster и др., 2021], [Röhm и др., 2018], [Köster и др., 2020]. Это обуславливает важность выбора времени ввода данных в систему.

Для параметров системы (η, P) , при которых наблюдается максимальная емкость памяти, проведен анализ появления резонансов, связанных со временем ввода входных данных (рис. 3). Время запаздывания τ было постоянным, менялось τ_{sym} .




Рис. 3. Зависимость емкости памяти от времени ввода данных. Панели слева (a, c, e) соответствуют отрицательной обратной связи, справа (b, d, f) – положительной, верхние панели (a, b) рассчитаны для $\tau_L = 1$, $P = 0.4$, $\eta = \pm 0.61$, средние (c, d) – $\tau_L = 7.5$, $P = 0.2$, $\eta = \pm 0.98$ и нижние (e, f) для $\tau_L = 10$, $P = 0.1$, $\eta = \pm 0.99$

Из рис. 3 следует, что при увеличении τ_L , число резонансов сначала возрастает (рис. 3,c,d), а затем уменьшается (рис. 3,e,f), что соответствует увеличению и уменьшению емкости памяти на рис. 2. Также резонансы становятся глубже и уже при увеличении τ_L . Для $\tau_L = 1$ при $\tau_{sym} = \tau$

система находится внутри резонанса, таким образом, можно увеличить значение емкости памяти системы, приведенное на рис. 2, изменив τ_{sym} . При $\tau_L = 7.5$ и 10 система находится за пределами резонансного провала. Это связано как с тем, что сам резонанс смещается вследствие увеличения периода собственных колебаний из-за увеличения инертности обратной связи, так и с тем, что он становится более узким вследствие увеличения добротности системы.

Для тех же параметров, что и на рис. 3, был проведен анализ влияния на емкость памяти как времени ввода данных в систему, так и времени запаздывания петли обратной связи.




Рис. 4. Значение емкости памяти в плоскости параметров времени ввода данных и времени запаздывания петли обратной связи (τ_{sym} , τ).
Остальные параметры аналогичны рис. 3

Рис. 4 демонстрирует эффект уменьшения емкости памяти при совпадении времени ввода данных в систему с одним из периодов собственных колебаний системы, кратных τ , который также продемонстрирован в работах [Köster и др., 2020], [Röhm и др., 2019]. Отчетливо видно снижение MC при $\tau_{sym} \approx n * \tau$, где $n = 1, 2, 3$.

Поскольку рис. 3 и 4 были выполнены для конкретных значений параметра накачки P и силы обратной связи η , была рассчитана емкость памяти для времени ввода символа в систему равной $\tau_{sym} = 1.1 * \tau$ для диапазона параметров (η , P).




Рис. 5. Емкость памяти в плоскости параметров силы обратной связи и параметра накачки (η , P) для $\tau_{sym} = 1.1 * \tau$. Сверху вниз τ_L : 1, 7.5 и 10. Белые линии показывают границы бифуркаций Андронова-Хопфа

Как видно, асимметрия сохраняется для всех анализируемых параметров при изменении периода ввода данных в систему. По сравнению с $\tau_{sym} = \tau$ (рис. 2), наблюдается увеличение емкости памяти для наименьшего значения $\tau_L = 1$. Максимальная $MC = 38$ достигается для $\tau_L = 7.5$ в аналогичной области, что и для $\tau_{sym} = \tau$.

Заключение

В работе исследована система резервуарных вычислений на основе полупроводникового лазерного диода с оптоэлектронной обратной связью, сигнал которой подвергался полосовой фильтрации по частоте. Система моделировалась на основе дифференциальных уравнений с запаздывающим аргументом (1.1)–(1.4). Проведено исследование влияния резонансов на емкость памяти системы резервуарных вычислений. Продемонстрировано резкое уменьшение емкости памяти в окрестности резонансов между временем ввода данных в систему и периодами собственных колебаний системы. Показано, что с уменьшением полосы пропускания обратной связи положения резонансных провалов емкости памяти системы смещаются в сторону больших времен ввода входных данных, увеличивается число резонансов и уменьшается их ширина.

Список литературы

- [**Appeltant, 2012**] Appeltant L. Reservoir computing based on delay-dynamical systems: дис. – Universitat de les Illes Balears, 2012.
- [**Argyris и др., 2018**] Argyris A., Bueno J., Fischer I. Photonic machine learning implementation for signal recovery in optical communications // Scientific reports. – 2018. – Vol. 8, No. 1. – P. 1-13.
- [**Chembo, 2020**] Chembo Y.K. Machine learning based on reservoir computing with time-delayed optoelectronic and photonic systems // Chaos: An Interdisciplinary Journal of Nonlinear Science. – 2020. – Vol. 30, No. 1. – P. 013111.
- [**Dmitriev и др., 2020**] Dmitriev P.S. и др. Asymmetrical performance of a laser-based reservoir computer with optoelectronic feedback // Optics Letters. – 2020. – Vol. 45, No. 22. – P. 6150-6153.
- [**Gonon и др., 2020**] Gonon L., Grigoryeva L., Ortega J. P. Memory and forecasting capacities of nonlinear recurrent networks // Physica D: Nonlinear Phenomena. – 2020. – Vol. 414. – P. 132721.
- [**Jaeger, 2002**] Jaeger H. Short term memory in echo state networks. gmd-report 152 // GMD-German National Research Institute for Computer Science. – <http://www.faculty.jacobs-university.de/hjaeger/pubs/STMEchoStatesTechRep.pdf>. – 2002.
- [**Köster и др., 2020**] Köster F., Ehlert D., Lüdge K. Limitations of the recall capabilities in delay-based reservoir computing systems // Cognitive Computation. – 2020. – P. 1-8.
- [**Köster и др., 2021**] Köster F., Yanchuk S., Lüdge K. Insight into delay based reservoir computing via eigenvalue analysis // Journal of Physics: Photonics. – 2021. – Vol. 3, No. 2. – P. 024011.
- [**Larger и др., 2017**] Larger L. и др. High-speed photonic reservoir computing using a time-delay-based architecture: Million words per second classification // Physical Review X. – 2017. – Vol. 7, No. 1. – P. 011015.
- [**Lugnan и др., 2020**] Lugnan A. и др. Photonic neuromorphic information processing and reservoir computing // APL Photonics. – 2020. – Vol. 5, No. 2. – P. 020901.
- [**Maass, 2002**] Maass W., Natschläger T., Markram H. Real-Time Computing Without Stable States: A New Framework for Neural Computation Based on Perturbations. – 2002. – P. 2531-2560.
- [**Röhm и др., 2018**] Röhm A., Lüdge K. Multiplexed networks: reservoir computing with virtual and real nodes // Journal of Physics Communications. – 2018. – Vol. 2, No. 8. – P. 085007.
- [**Röhm и др., 2019**] Röhm A., Jaurigue L., Lüdge K. Reservoir computing using laser networks // IEEE Journal of Selected Topics in Quantum Electronics. – 2019. – Vol. 26, No. 1. – P. 1-8.

ГИБРИДНЫЙ АЛГОРИТМ РЕШЕНИЯ ЗАДАЧИ РАЗМЕЩЕНИЯ ЭЛЕМЕНТОВ ЭВА

Л.А. Гладков (*leo_gladkov@mail.ru*)

М.Д. Ясир (*yasir_82@mail.ru*)

Н.В. Гладкова (*nadyusha.gladkova77@mail.ru*)

Южный федеральный университет, Таганрог

В статье обсуждается проблема размещения разноразмерных элементов. Приведена постановка задачи, а также основные ограничения и критерий оптимизации. Разработана модель гибридного алгоритма решения задачи размещения. Предложена модель параллельного многопопуляционного генетического алгоритма. Разработана процедура, позволяющая реализовать принцип многопоточности на локальном уровне, при расчёте значений целевых функций. Описаны принципы работы и структура блока нечеткого управления. Предложена модель многослойной нейронной сети, реализующая функцию блока нейро-нечеткого управления. Выбраны управляющие параметры генетического алгоритма. Предлагаемый гибридный алгоритм реализован в виде прикладной программы. Проведена серия вычислительных экспериментов для определения эффективности разработанного алгоритма и выбора оптимальных значений управляющих параметров.

Ключевые слова: конструкторское проектирование, биоинспирированные алгоритмы, нечеткое управление, гибридные системы, параллельные вычисления.

Введение

В настоящее время процесс проектирования невозможно представить без применения вычислительной техники. Сложность проектируемых устройств, число элементов и связей между ними непрерывно растет. На данный момент идет об устройствах содержащих порядка 10^4 элементов. Решать возникающие задачи такого уровня сложности путем полного перебора вариантов существующие вычислительные устройства пока не позволяют [Shervani, 1995]. На некоторых этапах проектирования отсутствуют детерминированные вычислительные методы, что не позволяет решить задачу выполнения проектирования в полностью автоматическом

режиме. Поэтому актуальной остается задача разработки эвристических методов оптимизации, позволяющих получать приемлемые по качеству решения за полиномиальное время.

Совершенствование технологий изготовления привело к пересмотру некоторых принципов, на которых основан процесс физического проектирования [Charles etc, 2009]. Это в свою очередь привело к пересмотру актуальных критериев оценки качества размещения. Использувавшиеся ранее критерии, построенные на модели оценки временных задержек пропорционально суммарной длине соединений стали неактуальными, изменилась концепция процесса физического проектирования вычислительных устройств.

Одним из основных трендов современной науки является гибридизация, т.е. создание новых систем, моделей и методов, подразумевающих интеграцию научных подходов различной физической природы. Хорошие результаты позволяет получить использование биоинспирированных алгоритмов в качестве инструмента поиска оптимальных решений. В настоящее время предложено большое число разновидностей биоинспирированных алгоритмов для решения различных задач оптимизации [Гладков и др., 2009]. Особенно эффективно использование таких систем для решения сложных слабо формализованных задач, в том числе задач проектирования и оптимизации [Sohoon etc, 2003].

В данной статье предлагается гибридный подход к решению задачи размещения элементов ЭВА на основе интеграции различных подходов, таких как, эволюционные алгоритмы поиска, нейронные сети, нечеткие методы управления параметрами алгоритма и механизмы распараллеливания вычислений [Гладков, 2000].

1. Постановка задачи

После решения задачи разбиения электрических цепей можно выполнить оценочный расчет площади, занимаемой каждым блоком и определить необходимое число контактов (выводов). Перед началом трассировки, проектировщику нужно расположить блоки на поверхности кристалла и соединить их выводы между собой в соответствии с заданным списком соединений. Расположение блоков осуществляется на этапе размещения, а соединение осуществляется на этапе трассировки [Charles etc, 2009].

На этапе размещения элементы должны быть расположены на рабочей поверхности таким образом, чтобы любые два блока не имели взаимного перекрытия, и, при этом, оставалось достаточно места для проведения соединений. Элементы должны быть размещены таким образом, чтобы минимизировать занимаемую площадь.

Для простоты предполагается, что все блоки имеют прямоугольную форму. Как правило, для определения формы блока используют соотношение сторон, т.е. отношение высоты блока к его ширине. Для определения допустимых размеров задают верхнюю и нижнюю границы соотношения сторон.

Алгоритмы размещения на уровне платы нацелены на решение следующих задач: минимизация числа слоев при трассировке и соблюдение требований по производительности системы. Длина критических связей в высокопроизводительных цепях должна быть меньше заданного значения, следовательно, элементы таких цепей должны размещаться максимально близко друг к другу. Другой важнейшей проблемой является соблюдение температурного режима. Теплопровод в схеме должен быть равномерным, значит блоки, выделяющие наибольшее количество тепла, должны располагаться близко друг к другу. Эти и другие требования могут противоречить друг другу.

Пусть задано множество элементов E_1, E_2, \dots, E_n , которые должны быть размещены на рабочей поверхности. Известны габаритные размеры (высота h_i и ширина w_i) каждого элемента E_i , $1 \leq i \leq n$. Также задано множество цепей $N = \{N_1, N_2, N_3, \dots, N_m\}$, множество свободных позиций $R = \{R_1, R_2, \dots, R_n\}$ и множество прямоугольных областей $Q = \{Q_1, Q_2, \dots, Q_k\}$, в которых будет выполняться трассировка. Оценочную длину цепи N_i , $1 \leq i \leq m$ обозначим как L_i .

Тогда задача размещения состоит в том, чтобы найти для каждого элемента множества E подходящую по размеру позицию на рабочей поверхности так, чтобы соблюдались следующие условия:

1. Любой элемент множества E_i можно поместить в одну из свободных позиций множества R_j .

2. Никакие две позиции не перекрываются, то есть $R_i \cap R_j = \emptyset$, $1 \leq i, j \leq n$.

3. Размещение является трассируемым, т.е. площади Q_i , $1 \leq j \leq k$, достаточно для трассировки всех цепей.

4. Общая площадь прямоугольника, ограничивающего области R и Q , является минимальной.

5. Общая длина соединений $\sum_{i=1}^m L_i$ минимизируется. При наличии в схеме высокопроизводительных цепей длина самой длинной цепи $\max\{L_i \mid i = 1, \dots, m\}$ минимизируется.

В качестве критерия оптимизации используется аддитивная функция:

$$F = \min_{z_j \in Z} (k \cdot O(L(z_j)) + P(S_{\text{общ}}(z_j))),$$

где z_j – текущий вариант размещения; k – весовой коэффициент; $S_{\text{общ}}$ – суммарная площадь перекрытия элементов; $O(L(z_j))$ – оценка длины соединений; $P(S_{\text{общ}}(z_j))$ – штраф за перекрытие площадей.

2. Описание гибридного алгоритма

Для решения задачи размещения предложен параллельный многопопуляционный генетический алгоритм. Он предполагает параллельное выполнение эволюционных процессов на нескольких популяциях. Для обмена особями используется островная модель параллельного генетического алгоритма [Alba etc, 2002].

В островной модели синхронизация параллельных процессов осуществляется в точках миграции. Миграция осуществляется при наступлении определённых событий, которые могут произойти в любой популяции. При наступлении события в одной из популяций, выполнение эволюции приостанавливается. Миграция осуществляется между двумя соседними популяциями [Zhongyang etc, 2006].

С помощью оператора миграции выполняется обмен решениями между популяциями. Хромосомы для миграции отбираются из хромосом популяции, имеющих лучшее значение функции пригодности. Затем выполняется обмен между популяциями с помощью копирования нескольких решений с лучшими значениями функции пригодности. Чтобы размер популяции не изменялся, из популяции одновременно удаляется такое же количество хромосом с худшим значением функции пригодности. На рис. 1 представлена схема предложенной модели параллельного генетического алгоритма, выполняемого на 2-х популяциях [Гладков, 2010]. На практике количество популяций может быть значительно больше.

Важно правильно подобрать частоту выполнения оператора миграции (интервал времени между миграциями) и число хромосом, участвующих в миграции. При слишком большой частоте возникает опасность перемешивания решений и преждевременной сходимости генетического алгоритма. Такая же ситуация возникает и при малой частоте миграции. Поэтому для определения вероятности выполнения оператора в разработанном алгоритме используется модуль нечёткого управления. Вероятность выполнения оператора миграции, наряду с вероятностями кроссинговера и мутации, определяется на основе данных об эффективности эволюции в каждом процессе.

Увеличение быстродействия алгоритма решения задачи размещения достигается путем организации параллельных эволюционных вычислений, а также за счёт использования многопоточности на локальном уровне, при расчёте значений целевых функций. Вычисление значения целевой функции каждой хромосомы выполняется в отдельном потоке. Популяция делится на S/N блоков хромосом, где S – размер популяции, N – предустановленное количество потоков расчёта целевой функции. Каждый блок содержит N хромосом. Для каждой хромосомы расчёт значения целевой функции запускается в отдельном потоке. После заверше-

ния всех запущенных потоков начинается вычисление значений целевой функции хромосом следующего блока. Процесс продолжается пока не будут найдены значения целевой функции для всех хромосом. Схема процедуры распараллеливания расчёта значений ЦФ представлена на рис. 2.

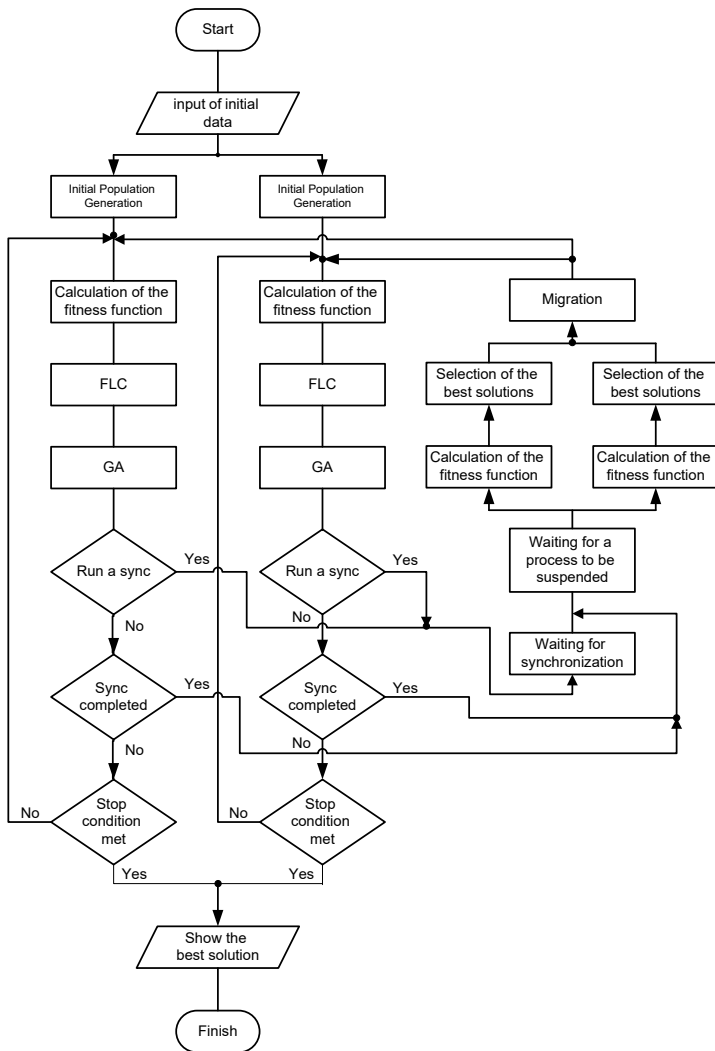


Рис. 1. Схема параллельного алгоритма

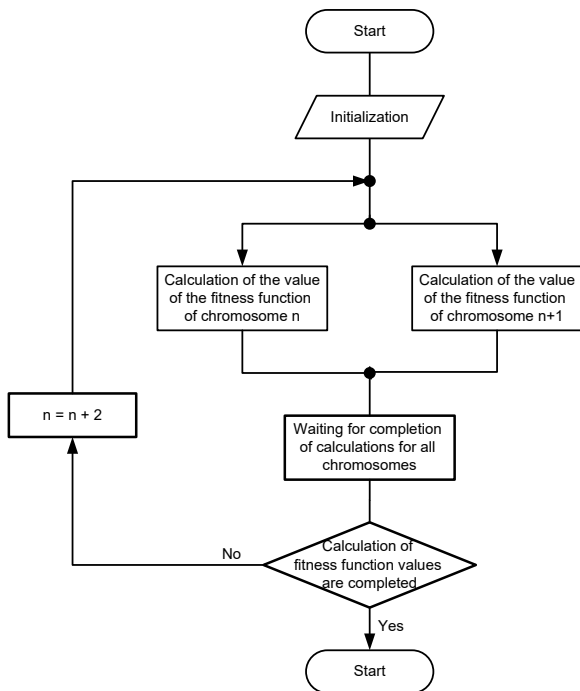


Рис. 2. Схема распараллеливания расчета целевой функции.

Модуль нечеткого управления (нечеткий логический контроллер) состоит из четырех взаимосвязанных блоков: блок фаззификации, база правил, блок дефаззификации, блок вывода [Michael etc, 1993].

База правил состоит из набора нечетких правил [Herrera etc, 1996]. Каждое из нечетких правил записывается в виде логической конструкции: IF ... THEN ... С точки зрения теории множеств нечеткие правила представляют собой нечеткое отношение $R^{(k)}$. Функция принадлежности такого нечеткого множества – это нечеткая импликация

$$\mu_{R^{(k)}}(x, y) = \mu_{A^k \rightarrow B^k}(x, y), \quad (1)$$

Блок фаззификации выполняет трансформацию чётких данных в нечеткие множества. Для этой цели часто используют представление нечеткой величины в виде синглтона.

Процедура получения результата нечеткого вывода с использованием базы правил состоит из следующих шагов [Herrera etc, 2003]:

1. Определение уровня срабатывания каждого из правил.
2. Определение результата нечеткого вывода по каждому из правил.
3. Агрегирование индивидуальных результатов нечеткого вывода в общий результат, характерный для всей базы нечетких правил.

Для оценки эффективности эволюционного процесса могут использоваться различные параметры, например, значения функции пригодности лучшего решения в популяции, средняя целевая функция текущей популяции, изменение среднего значения целевой функции популяции и т.д. [Ярушкина и др., 2007].

При разработке структуры модуля нечеткого управления необходимо также определиться с формой представления нечетких множеств. Для этого можно использовать, например, функцию Гаусса [Рутковская и др., 2004]:

$$\mu_{A_j^k}(x_i) = \exp\left(-\left(\frac{x_i - x_j^{-k}}{\sigma_j^k}\right)^2\right), \quad (2)$$

где x_j^{-k} – центр, а σ_j^k – ширина Гауссовой кривой.

Результирующая функция модуля нечеткого управления имеет следующий вид:

$$\bar{y} = \frac{\sum_{k=1}^N y^{-k} \left(\prod_{i=1}^n \exp\left(-\left(\frac{x_i - x_j^{-k}}{\sigma_j^k}\right)^2\right) \right)}{\sum_{k=1}^N \left(\prod_{i=1}^n \exp\left(-\left(\frac{x_i - x_j^{-k}}{\sigma_j^k}\right)^2\right) \right)}. \quad (2)$$

Каждый элемент можно задать в форме функционального блока (сумма, произведение, функция Гаусса). Объединение функциональных блоков дает многослойную нейронную сеть. Для решения поставленной задачи была использована модель нейронной сети, которая имеет 4 слоя (L1–L4), 4 входных элемента и один выход. Элементы первого слоя реализуют вышеприведенную функцию Гаусса. Элементами нейронной сети являются мультипликаторы, сумматоры и делитель.

Модуль нечеткого управления на основании оценки заданных контрольных значений может изменять значения вероятности выполнения генетических операторов. В качестве контрольных значений могут использоваться различные характеристики популяции, например, разнообразие генотипа и фенотипа популяции, величина лучшего и среднего

значения функции пригодности в текущей популяции, динамика изменения лучшего решения и среднего значений функции пригодности [Gladkov etc, 2020].

В предложенном алгоритме для оценки текущего состояния были выбраны 4 параметра [Gladkov etc, 2019]:

$$e_1(t) = \frac{f_{ave}(t) - f_{best}(t)}{f_{ave}(t)}; \quad e_2(t) = \frac{f_{ave}(t) - f_{best}(t)}{f_{worst}(t) - f_{best}(t)};$$

$$e_3(t) = \frac{f_{best}(t) - f_{best}(t-1)}{f_{best}(t)}; \quad e_4(t) = \frac{f_{ave}(t) - f_{ave}(t-1)}{f_{ave}(t)},$$

где t – номер текущей популяции, $f_{best}(t)$, $f_{worst}(t)$, $f_{ave}(t)$ – лучшее, худшее и среднее значение целевой функции на итерации t соответственно, $f_{best}(t-1)$, $f_{ave}(t-1)$ – лучшее и среднее значение ЦФ на итерации $(t-1)$.

В качестве выходных параметров блока нечеткого управления используются значения вероятностей выполнения основных генетических операторов: кроссинговера $Pc(t)$, мутации $Pm(t)$ и миграции $Pmg(t)$.

Для хранения данных о топологии печатной платы используется LEF/DEF спецификация. LEF (Library Exchange Format) – это спецификация для представления физической структуры микросхемы в формате ASCII. Она включает правила оформления и абстрактную информации об элементах. LEF используется в сочетании с DEF (Design Exchange Format) спецификацией, которая используется для представления полного размещения элементов микросхемы.

3. Программная реализация

Для создания графического интерфейса использовался фреймворк Qt 5.6. Qt – представляет из себя кросс-платформенный инструментальный разработки прикладного программного обеспечения, широко используемый для создания графических интерфейсов. Он написан на C++ и предоставляет мощные расширения этого языка. Включает в себя все основные классы, которые могут потребоваться при разработке прикладного программного обеспечения, начиная от элементов графического интерфейса и заканчивая классами для работы с сетью, базами данных и XML. Qt является полностью объектно-ориентированным, легко расширяемым и поддерживающим технику компонентного программирования.

Для визуализации и анализа работы нечёткого логического контроллера и алгоритма размещения можно вывести на экран графики изменения входных и выходных параметров контроллера (рис. 3).

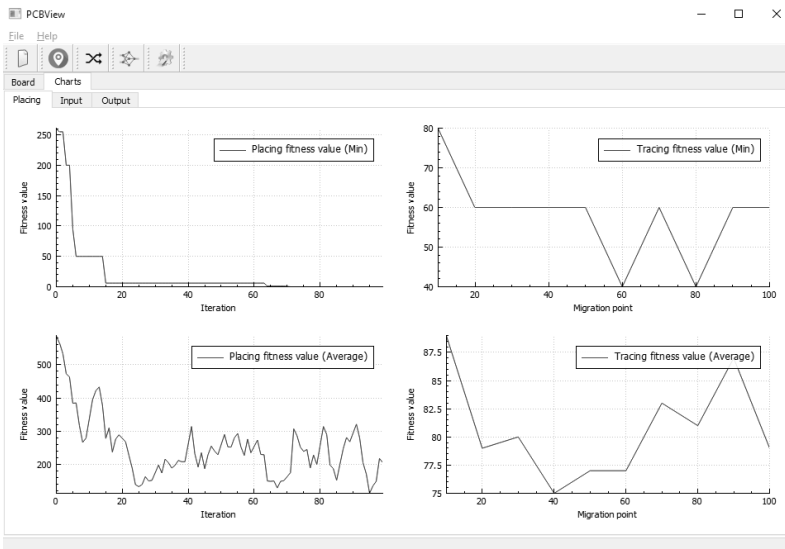


Рис. 3. Графики изменения параметров алгоритма

Предложена структура гибридного алгоритма решения задачи размещения разногабаритных элементов, разработаны модифицированные генетические операторы, а также компоненты гибридного алгоритма.

В настоящее время выполнена программная реализация и проводятся серии вычислительных экспериментов для определения оптимальных параметров алгоритма и изучения эффективности предложенного подхода.

Список литературы

- [Shervani, 1995] Shervani N. Algorithms for VLSI physical design automation. USA, Kluwer Academy Publisher, 1995.
- [Charles etc, 2009] Charles J. Alpert, Dinesh P. Mehta, Sachin S. Sapatnekar. Handbook of algorithms for physical design automation. – CRC Press, New York, USA, 2009.
- [Гладков и др., 2009] Гладков Л.А., Курейчик В.М., Курейчик В.В., Сороколетов П.В. Биоинспирированные методы в оптимизации. – М.: Физматлит, 2009.
- [Cohon etc, 2003] Cohoon J.P., Karro J., Lienig J. Evolutionary Algorithms for the Physical Design of VLSI Circuits. Advances in Evolutionary Computing: Theory and Applications / Ghosh A., Tsutsui S. (eds.). – Springer Verlag, London, 2003. – P. 683-712.
- [Alba etc, 2002] Alba E., Tomassini M. Parallelism and evolutionary algorithms // IEEE T. Evolut. Comput. – 2002. – Vol. 6. – P. 443-461

- [**Zhongyang etc, 2006**] Zhongyang X., Zhang Y., Zhang L., Niu S. A parallel classification algorithm based on hybrid genetic algorithm // Proc. of the 6th World Congress on Intelligent Control and Automation, Dalian, China, 2006. – P. 3237-3240
- [**Гладков, 2000**] Гладков Л.А. О некоторых подходах к построению гибридных интеллектуальных систем для решения графовых задач // Новости искусственного интеллекта. – 2000. – № 3. – С. 71-90.
- [**Гладков и др., 2010**] Гладков Л.А., Курейчик В.В., Курейчик В.М. Генетические алгоритмы. – М.: Физматлит, 2010.
- [**Michael etc, 1993**] Michael A., Takagi H. Dynamic control of genetic algorithms using fuzzy logic techniques // Proc. of the 5th International Conference on Genetic Algorithms. Morgan Kaufmann. 1993. – P. 76-83.
- [**Herrera etc, 1996**] Herrera F., Lozano M. Adaptation of genetic algorithm parameters based on fuzzy logic controllers / In: F. Herrera, J.L. Verdegay (eds.) // Genetic Algorithms and Soft Computing. Physica-Verlag, Heidelberg, 1996. – P. 95-124.
- [**Herrera etc, 2003**] Herrera F., Lozano M. Fuzzy Adaptive Genetic Algorithms: design, taxonomy, and future directions // Soft Computing. – Springer-Verlag, 2003. – 7. – P. 545-562.
- [**Ярушкина и др., 2007**] Нечеткие гибридные системы. Теория и практика / под ред. Н.Г. Ярушкиной. – М.: Физматлит, 2007.
- [**Рутковская и др., 2004**] Рутковская Д., Пилиньский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. – М.: Горячая линия-Телеком, 2004.
- [**Gladkov etc, 2020**] Gladkov L.A., Gladkova N.V., Gusev N.Y., Semushina N.S. Integrated approach to the solution of computer-aided design problems // Proceedings of the 4th International Scientific Conference “Intelligent Information Technologies for Industry” (ITI'19). Advances in Intelligent Systems and Computing. – Springer, Cham, 2020. – Vol. 1156. – P. 465-476.
- [**Gladkov etc, 2019**] Gladkov L.A., Gladkova N.V., Leiba S.N., Strakhov N.E. Development and research of the hybrid approach to the solution of optimization design problems // Advances in Intelligent Systems and Computing. Vol. 875 // International Conference on Intelligent Information Technologies for Industry ITI'18. – Springer Nature Switzerland AG, 2019. – Vol. 2. – P. 246-257.

УДК 004.891.3

ПРИМЕНЕНИЕ ТЕОРИИ СВИДЕТЕЛЬСТВ ДЛЯ ОБУЧЕНИЯ НЕЧЕТКИХ НЕЙРОННЫХ СЕТЕЙ ANFIS/TSK В ДИАГНОСТИЧЕСКИХ СИСТЕМАХ*

В.К. Иванов (*mtivk@mail.ru*)

Б.В. Палюх (*pboris@tstu.tver.ru*)

Тверской государственный технический университет, Тверь

В работе обосновывается метод создания обучающих наборов данных для нечетких нейронных сетей, которая может быть использована для оперативного получения вероятностных оценок причин аномальных критических событий или инцидентов в диагностических системах. Рассматриваются правила преобразования гипотез о потенциальных причинах инцидентов в интервалы вероятности дефекта технологической цепи на некоторой стадии непрерывного производства с использованием функций доверия. Предлагается процедура автоматического преобразования этих гипотез в базу нечетких продукционных правил, которая обеспечивает обучение нейронной сети ANFIS с алгоритмом нечеткого вывода Такаги-Сугено-Канга. Это позволит оперативно вычислить относительно точную вероятностную оценку неисправности в технологической цепи без использования затратных вычислительных ресурсов.

Ключевые слова: диагностическая система, инцидент, многостадийный технологический процесс, нечеткая логика, нечеткая нейронная сеть, продукционное правило, теория свидетельств, технологическая цепь, функция доверия, функция принадлежности, ANFIS, TSK.

Введение

Характерная для сложных многостадийных технологических процессов неопределённость при получении и анализе данных может иметь критический характер для непрерывных производств. Существенным обстоятельством является непростая формализация задач снижения неопределённости с учетом трудоёмкости требуемых вычислений. Одной из таких задач является алгоритмизация совместной обработки первичных данных

* Работа выполнена при финансовой поддержке РФФИ (проект № 20-07-00199).

о состоянии технологического процесса для получения вероятностных оценок аномальных критических событий или инцидентов. Решение этой задачи позволяет с заданной погрешностью установить неисправность определенной единицы технологического оборудования. Постановка сформулированной задачи основана на следующем подходе.

Гипотезы о потенциальных причинах инцидентов с использованием функций доверия (основы теории свидетельств) формализуются интервалом вероятности дефекта технологической цепи на некоторой стадии производства. Предлагается процедура автоматического преобразования этих гипотез в нечеткие продукционные правила, которая является предпосылкой к применению нечетких нейронных сетей для получения достоверной оценки степени уверенности в причине инцидента. обосновывается использование сгенерированной базы продукционных правил для обучения нейронной сети ANFIS с алгоритмом нечеткого вывода Такаги-Сугено-Канга (далее ANFIS/TSK). Это позволяет оперативно вычислить относительно точную оценку вероятности неисправности в технологической цепи без ресурсоемких вычислений.

Далее в статье описывается исходная модель диагностики технологического процесса, на основе которой предлагаются методы формирования нечетких множеств аномальных критических событий (инцидентов) и неисправных технологических цепей (причин инцидентов). Обосновывается структура и способ генерации продукционных правил, которые могут быть эффективно использованы для получения набора данных для обучения нейронной сети с архитектурой ANFIS/TSK.

1. Модель диагностики технологического процесса

Рассмотрим многостадийный непрерывный производственный *технологический процесс* $F = \{f_1, \dots, f_n, \dots, f_N\}$ с N производственными стадиями $f_n = (c_n, X_n, R_n)$ где n – номер производственной стадии f_n ; $c_n = \{c_{n1}, \dots, c_{nu}, \dots, c_{nU}\}$ – *технологическая цепь* (ТЦ) производства, реализующего производственную стадию f_n , $|c_n| = U$; c_{nu} – отдельная единица технологического оборудования с номером u , используемая на производственной стадии f_n ; $X_n = \{\bar{x}_{nm}\}$ – множество *диагностических переменных* (ДП) \bar{x}_{nm} ; m – порядковый номер ДП для \bar{x}_{nm} , $m = 1, 2, \dots, |X_n|$.

Замечание 1. Все ДП являются выходными технологическими переменными для диагностируемого оборудования ТЦ, значения которых поступают от сенсоров оборудования. Если принять, что одна единица технологического оборудования в ТЦ характеризуется одной основной ДП, то значения ДП определяют эффективность функционирования данной единицы оборудования на соответствующей стадии.

Каждая ДП есть кортеж $\bar{x}_{nm} = (o_{nm}, x_{nm}, d_{nm})$, где:

o_{nm} – уникальное имя ДП;

d_{nm} – интервал нормативных значений ДП;

$x_{nm} = (x_{nm1}, \dots, x_{nmv}, \dots, x_{nmV})$ – кортеж значений ДП;

$x_{nm} = [\underline{x}_{nm}, \bar{x}_{nm}]$ – интервальные значения ДП o_{nm} , определяющие некоторое состояние F по o_{nm} на выходе из c_n на стадии f_n за некоторый временной интервал наблюдения $T = [t, \bar{t}]$. Для значений x_{nm} задана область определения $D(x_{nm}) = \{\underline{x}, \dots, \bar{x}\}$, причем $\underline{x} \leq \underline{x}_{nm} \leq \bar{x}_{nm} \leq \bar{x}$;

$d_{nm} = [d_{nm}, \bar{d}_{nm}]$ – интервал нормативных (допустимых) значений ДП o_{nm} , определяющих состояние нормальной работоспособности F по o_{nm} на выходе из o_{nm} на стадии f_n ;

R_n – множество переменных для управления c_n .

Введем понятие *инцидента по o_{nm}* , которое соответствует аномальному критическому событию, которое определяется ненормативными значениями x'_{nm} . В процессе эксплуатации непрерывного технологического процесса формируется нечеткое множество инцидентов $X' = \{(x'_{nm}, \mu_I(x'_{nm}) \mid x'_{nm} \in X'\} \subseteq X$, где $\mu_I(x'_{nm}) \in [0, 1]$ – функция принадлежности x'_{nm} множеству X' , а $X = \bigcup_N x_n = \{x_{nm} : \exists n x_{nm} \in x_n\}$ – множество значений всех ДП (базовое множество).

Замечание 2. Ненормативные значения могут возникать одновременно у некоторого количества ДП и определять возникновение одного конкретного инцидента с фиксацией x'_{nm} из различных $\bar{x}_{nm}, m = 1, 2, \dots$, но имеющих одну и ту же причину появления x'_{nm} .

Если в процессе функционирования ТЦ обнаружены значения x'_{nm} , то такое событие соответствует нечеткому множеству возможно дефектных ТЦ A , которое характеризует возможность наличия инцидента: $\forall P(x'_{nm}) \in P : P(x'_{nm}) = (0, 1] \rightarrow A\{(c_n; \mu_{nm}(c_n))\}, A \neq \emptyset$, где $P = \{P(x'_{nm})\}$ – множество признаков того, что инцидент произошел; $C = \{c_n\} \mid C \supseteq A$ – множество диагностируемых c_n ; $\mu_{nm}(c_n) = [0, 1]$ – функция принадлежности c_n множеству A или степень уверенности в том, что $c_n \in A$.

Рассмотрим способы вычисления функций принадлежности $\mu_I(x_{nm})$ и $\mu_{nm}(c_n)$.

2. Формирование нечеткого множества инцидентов

При вычислении функции принадлежности $\mu_I(x_{nm})$ формируется нечеткое множество инцидентов X' . Важно отметить, что выявление инцидентов (индикация аномальных критических событий) происходит с учетом того, что значение ДП всегда является интервалом $x_{nm} = [\underline{x}_{nm}, \bar{x}_{nm}]$. Для таких значений $\mu_I(x_{nm}) = (\mu_I(\underline{x}_{nm}) + \mu_I(\bar{x}_{nm}))/2$.

В общем случае $\mu_I(x_{nm})$ может быть представлена как «перевернутая» нечеткая π -образная функция принадлежности:

$$\mu_I(x_{nm}) = 1 - (\mu_1 \cdot c_1 + \mu_2 \cdot c_2 + \mu_3 \cdot c_3 + \mu_4 \cdot c_4 + \mu_5 \cdot c_5 + \mu_6 \cdot c_6 + \mu_7 \cdot c_7), \quad \text{где}$$

$$\mu_1 = 0, \quad \mu_2 = 2((x_{nm} - \underline{x}) / (\underline{d}_{nm} - \underline{x}))^2, \quad \mu_3 = 1 - 2((\underline{d}_{nm} - x_{nm}) / (\underline{d}_{nm} - \underline{x}))^2,$$

$$\mu_4 = 1, \quad \mu_5 = 1 - 2((x_{nm} - \bar{d}_{nm}) / (\bar{d}_{nm} - \bar{x}))^2, \quad \mu_6 = 2((\bar{x} - \bar{d}_{nm}) / (\underline{d}_{nm} - \bar{x}))^2,$$

$$\mu_7 = 0.$$

Логические переменные $c_1 = x_{nm} \leq \underline{x}$, $c_2 = \underline{x} < x_{nm} \leq (\underline{x} + \underline{d}_{nm})/2$, $c_3 = (\underline{x} + \underline{d}_{nm})/2 < x_{nm} < \underline{d}_{nm}$, $c_4 = \underline{d}_{nm} \leq x_{nm} \leq \bar{d}_{nm}$, $c_5 = \bar{d}_{nm} < x_{nm} \leq (\bar{d}_{nm} + \bar{x})/2$, $c_6 = (\bar{x} + \bar{d}_{nm})/2 < x_{nm} < \bar{d}_{nm}$, $c_7 = x_{nm} \geq \bar{d}_{nm}$ принимают значения «1» в случае их истинности и «0» в противном случае.

Графическая интерпретация функции $\mu_I(x_{nm})$ представлена на рис. 1. Используются следующие исходные данные: $\underline{x} = 10$, $\underline{d}_{nm} = 45$, $\bar{d}_{nm} = 55$, $\bar{x} = 100$; две кривых на графике отражают интервальные значения x_{nm} .

Возможны и другие варианты функций $\mu_I(x_{nm})$ [Халов, 2009]. Особенности применения некоторых из них описаны в [Ivanov et al., 2022].

Основные характеристики нечеткого множества инцидентов X' :

Интервалы $\underline{X}' = [\min(x'_{nm} | \mu(x'_{nm}) = 1), \underline{d}_{nm}]$, и $\bar{X}' = [\bar{d}_{nm}, \max(x'_{nm} | \mu(x'_{nm}) = 1)]$ определяют области неопределенности для x'_{nm} .

$X'_S = \{x_{nm} | \mu_I(x_{nm}) > 0, x_{nm} \in X\}$ – носитель X' ; содержит результаты измерений ненормативных значений x_{nm} ДП.

$X'_C = \{x_{nm} | \mu_I(x_{nm}) = 0, x_{nm} \in X\}$ – ядро X' ; содержит результаты измерений нормативных значений x_{nm} ДП.

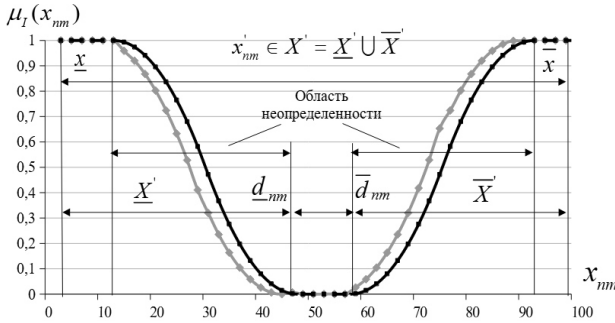


Рис. 1. Нечеткая π -образная функция принадлежности $\mu_i(x_{nm})$

3. Формирование нечеткого множества неисправных технологических цепей

Непустое множества инцидентов $X' \neq \emptyset$ есть следствие нарушения нормативного режима работы в одной или нескольких $c_n \in A$. При этом $\mu_{nm}(c_n)$ является функцией принадлежности c_n множеству A . Для определения $\mu_{nm}(c_n)$ мы предлагаем использовать алгоритмы теории свидетельств [Yager et al., 2010], подробности предложенного подхода описаны в [Ivanov et al., 2019], [Иванов и др., 2019]. В терминах указанной теории любые подмножества $x' \subseteq X'$ являются *событиями*.

Пусть $C = \{c_n\}$ – конечное множество диагностируемых ТЦ, а $A_i \subseteq C$ – любое подмножество потенциально неисправных ТЦ. Степень уверенности в том, что причина инцидента есть $c_n \in A_i$ выражается *функцией доверия* $Bel(A_i) | Bel(\emptyset) = 0, Bel(A_i) \in [0, 1]$. Величина $Pl(A_i) = 1 - (\bar{A}_i)$ называется *функцией правдоподобия*.

$Bel(A_i)$ и $Pl(A_i)$ рассматриваются как нижняя и верхняя границы функции принадлежности $\mu_{nm}(c_n)$: $Bel(A_i) \leq \mu_{nm}(c_n) \leq Pl(A_i)$. Назовем интервал значений функции $\mu_{nm}(c_n) = [Bel(A_i), Pl(A_i)]$ *гипотезой о причине инцидента*. Таким образом может быть получено множество гипотез о причинах инцидентов для всех A_i .

Базовые вероятностей $m(A_i)$ или предположения о причинах аномальных значений x'_{nm} , связанных с нарушением работоспособности ТЦ c_n , могут быть получены из экспертных оценок, статистических данных, технологических регламентов.

В случае экспертной оценки ситуация инцидента по заданной ДП оценивается экспертом как $m_e(A_i) = [0,1]$, причем множество A_i определяет эксперт.

В случае статистических данных об инцидентах эти данные должны быть представлены эмпирическим распределением (гистограммой) инцидентов по заданной ДП для A_i . Базовые вероятности генерируются с помощью известных алгоритмов. Например, вычислением относительных частот инцидентов с аддитивным сглаживанием: $m_s(A_i) = n_i / n + \lambda n_A$, где n – количество зафиксированных инцидентов; n_i – количество инцидентов, причина которых были неисправности в ТЦ из A_i ; $\lambda > 0$ – параметр сглаживания (обычно $\lambda = 0$).

В случае анализа технологических регламентов появляется возможность уточнения информации о вероятных неисправностях ТЦ, являющихся причинами инцидентов.

Отметим, что очевидна необходимость объединения тел свидетельств по данному инциденту, полученных из различных источников. Подробную информацию о правилах комбинирования можно найти в [Ferson, 2002]. Ключевым фактором при объединении тел свидетельств является их внутренняя и внешняя конфликтность, возникающая из-за часто объективной противоречивости информации. Анализ конфликтности свидетельств, способы построения мер конфликта и их формализация подробно рассмотрены в обзоре [Лепский, 2021].

4. Автоматическая генерация продукционных правил

Автоматическая генерация продукционных правил является основой предлагаемого метода создания наборов данных для обучения нечеткой нейронной сети. В этом разделе описываются ключевые положения указанного метода.

Продукционные правила (далее *правила*) имеют следующий общий вид: $R_i : \text{IF } \exists x'_{nm} \in X' \text{ THEN } \exists A \neq \emptyset$, где R_i – правило, $i = 1, 2, \dots, G$ – номер правила, G – общее число правил.

С помощью подобных правил естественным образом могут быть выражены гипотезы о причинах инцидентов. Вербально правило звучит так: если на какой-либо производственной стадии произошел инцидент, то его причиной является некоторое нечеткое множество ТЦ.

Представим общую структуру правила с учетом **Замечания 2** следующим образом:

$$R_i : \text{IF } \mu_1(o_{n1}, x'_{n1}) \text{ AND } \mu_1(o_{n2}, x'_{n2}) \text{ AND } \dots \text{ AND } \mu_1(o_{nm}, x'_{nm}) \text{ THEN } \mu_{nm}(c_n),$$

где

$\mu_i(o_{nm}, x'_{nm})$ – степень уверенности того, что ненормативное значение x'_{nm} привело к инциденту на производственной стадии f_n по ДП o_{nm} ;

o_{nm} – элемент кортежа $o'_n = (o_{n1}, \dots, o_{nm})$ лингвистических переменных – имен ДП;

x'_{nm} – элемент кортежа $x'_n = (x'_{n1}, \dots, x'_{nm})$ ненормативных значений входных ДП, $x'_n \subseteq X'$, X' – область определения антецедента R_i ;

$c_n \subseteq A$ – лингвистическая переменная, определяющая неисправную ТЦ (причину инцидента). A – область определения консеквента R_i (все потенциально неисправные ТЦ).

В совокупности такие правила представляют базу знаний, которая обычно формируется специалистами предметной области. Покажем, что подобная база знаний может быть сгенерирована автоматически. Для этого преобразуем структуру правила, учитывая обоснованную в разделе 3 возможность получения количественной оценки значения гипотезы о причине инцидента $\mu_{nm}(c_n) = [Bel(A_i), Pl(A_i)]$:

$$R_i^{cn} : \text{IF } x_1 \text{ is } \mu_{n1} \text{ AND } x_2 \text{ is } \mu_{n2} \text{ AND } \dots \text{ AND } x_m \text{ is } \mu_{nm} \text{ THEN } y = \mu_{cni},$$

где

R_i^{cn} – правило для c_n , i – номер правила, c_n – ТЦ на производственной стадии f_n , $\{R_i\} \cong \{c_{ni}\}$;

x_m – степень уверенности того, что ненормативное значение m -й ДП является индикатором инцидента (входная переменная);

μ_{nm}^i – значение x_m ;

y – степень уверенности того, что причина инцидента есть неисправность в c_{ni} (выходная переменная);

μ_{cni} – значение y , $\mu_{cni} = (Bel(A), Pl(A))/2$ (центр интервала $[Bel(A), Pl(A)]$). Значение μ_{nm}^i гарантированно лежит внутри $[Bel(A), Pl(A)]$ и является достоверной оценкой гипотезы c_n .

Таким образом, очевиден следующий вывод: используя вычисленные значения функций доверия и правдоподобия, можно автоматически сгенерировать базу правил для всех гипотез о причинах инцидентов. Пример фрагмента базы правил для ТЦ c_1 :

$$R_1^{c1} : \text{IF } x_1 = 0.755 \text{ THEN } y = 0,217, \quad R_2^{c1} : \text{IF } x_2 = 0.5 \text{ THEN } y = 0.563, \\ R_3^{c1} : \text{IF } x_1 = 0.755 \text{ AND } x_2 = 0.5 \text{ THEN } y = 0.317/$$

Мы предлагаем подобные автоматически сгенерированные базы продукционных правил использовать для обучения нечеткой нейронной сети с архитектурой ANFIS [Jang, 1993].

Сеть ANFIS/TSK реализует нечеткую продукционную модель, основанную на правилах следующего типа:

$$R_i : \text{IF } x_1 \text{ is } A_{i1} \text{ AND } \dots \text{ AND } x_m \text{ is } A_{im} \text{ THEN } y_i = c_{i0} + c_{i1}x_1 + \dots + c_{im}x_m ,$$

где

$i = 1, 2, \dots, G$ – номер правила;

$x_1, x_2, \dots, x_m, \dots, x_M$ – входные вещественные переменные, $m = 0, 1, \dots, M$;

$A_{i1}, A_{i2}, \dots, A_{im}, \dots, A_{iM}$ – нечеткие множества;

y_i – выходная вещественная переменная;

$c_{i0}, c_{i1}, \dots, c_{im}, \dots, c_{iM}$ – параметры консеквента для R_i (четкие числа).

Нетрудно заметить, что эти правила аналогичны по структуре правилам, полученным в результате формирования гипотез о причинах инцидентов. В них x_m интерпретируется как степень уверенности того, что ненормативное значение m -й ДП привело к инциденту, а y_i – как степень уверенности того, что причина инцидента есть неисправность в ТЦ c_n , для которой определено правило R_i .

Следовательно, решение исходной задачи определения достоверной вероятностной оценки неисправности ТЦ, как причины диагностированного инцидента, может быть найдено с помощью нечеткой нейронной сети ANFIS/TSK. При этом обучение сети может проводиться на наборах автоматически сгенерированных продукционных правил для гипотез о причинах инцидентов.

5. Обучение нейронной сети ANFIS/TSK

Для обучения нейронной сети использован исследовательский демонстратор «Статус-4», разработанный в рамках обсуждаемого проекта [Иванов др., 2021]. Цель разработки этого демонстратора – создание научно-технического задела для передачи готовых к внедрению решений на следующие этапы проекта. Демонстратор реализован как Web-приложение в среде Python/Flask. Базовые функции создания и обучения нейронной сети имплементированы на платформе TensorFlow. Также использованы свободно распространяемые библиотеки с открытым кодом, обеспечивающие расширенную функциональность: pyds [Reineking, 2014], TensorANFIS [Cuervo, 2022], AnfisTensorflow2.0 [Gregor, 2022].

Обучение нейронной сети в указанной программной среде предполагает выполнение следующих шагов:

1. *Создание (или выбор уже созданного) шаблона модели нейронной сети.* Задаваемые параметры: имя модели; число входных переменных x_1, x_2, \dots (регрессоров); начальное число правил R_i . Результат – шаблон модели в служебной базе данных.

2. *Создание (или выбор уже созданных) обучающего и проверочного наборов данных.* Задаваемые параметры описания набора данных: имя набора данных; идентификатор технологической цепи c_n ; диагностические переменные o_{nm} , число которых должно совпадать с числом входных переменных модели нейронной сети; число экземпляров данных для переменной (определяет число комбинаций регрессоров); метод комбинирования свидетельств; служебные параметры, такие как необходимость генерации промежуточных данных, генерации данных только для инцидентов журнализации, заголовков в данных. Результат – описания обучающего и проверочного наборов данных в служебной базе данных. Алгоритм генерации данных: для каждой возможной комбинации значений входных переменных вычисляются значения $\mu_i(x_{nm})$ (см. раздел 2) и значение $\mu_{nm}(c_n)$ (см. раздел 3); формируется очередная запись набора, которая добавляется к итоговому набору данных в формате CSV. Отметим, что среднее время формирования записи набора, то есть время аналитического расчета комбинированной вероятностной оценки, составляет около 0,0050...0,0075 с.

3. *Задание гиперпараметров обучения нейронной сети.* На этом шаге должен выполняться подбор эффективных значений гиперпараметров данной модели: идентификаторы обучающего и проверочного наборов, данных; число правил R_i ; уровень обучения; функция потерь (Huber loss, MSE или MAPE); метод оптимизации (ADAM, RMSProp, градиентного спуска), число эпох.

5. *Обучение нейронной сети.* Выполняется соответствующая программная процедура использующая данных обучающего набора. Рис. 2 на примере иллюстрирует динамику изменения потерь при обучении нейронной сети.

Отметим небольшое количество эпох (не более 80), потребовавшееся для получения приемлемого уровня обучения (итоговые потери в среднем не превышают 0,0030). Также можно говорить о приемлемом качестве обучения, учитывая хорошее совпадение кривых. Заданные параметры обучения приведены на графике.




Рис. 2. Изменение функции потерь при обучении нейронной сети

6. Проверка качества нейронной сети. На рис. 3 представлен пример результата проверки качества нейронной сети. Проверка производилась сравнением исходных значений $\mu_{nm}(c_n)$, представленных в проверочном наборе данных, со значениями, вычисленными нейронной сетью. Видно достаточно хорошее совпадение действительных и предсказанных значений. Сеть в данном примере была обучена с использованием параметров предыдущего примера. Отметим, что среднее время вычисления нейронной сетью вероятностной оценки неисправности составляет около 0,0010 с (в вычислительных экспериментах использовался компьютер с ACPI на базе x64 с 6-ти ядерным процессором Intel Core i5-10300H CPU 3.2GHz, памятью DDR4 8 Gb, 64-разрядной ОС Windows 10 Pro).




Рис. 3. Соответствие предсказанных и действительных значений

$$\mu_{nm}(c_n)$$

Заключение

Описанный в статье подход позволяет выполнять вычисления вероятностных оценок причин неисправностей в технологических цепях без использования затратных вычислительных ресурсов. Это достигается за счет:

- применения алгоритмов теории свидетельств при формировании гипотез о причинах инцидентов;
- автоматического создания базы продукционных правил для гипотез о причинах инцидентов;
- обучения нечеткой нейронной сети ANFIS/TSK с помощью наборов данных, построенных на основе базы продукционных правил для гипотез о причинах инцидентов;
- использования нечеткой нейронной сети ANFIS/TSK для определения достоверной вероятностной оценки неисправности технологической цепи, как причины диагностированного инцидента.

Подготовленные модели могут быть применены в интеллектуальных системах диагностики сложных многостадийных процессов. Поскольку время выполнения расчетов нейронной сетью в разы превышает соответствующее время выполнения аналитических расчетов комбинированных вероятностных оценок, актуальным представляется диагностические системы реального времени с большими объемами потоковых данных от сенсоров.

Эффективность предложенного подхода требует дополнительного экспериментального подтверждения, однако уже имеющиеся результаты дают основание для положительной перспективы.

Список литературы

- [Халов, 2009] Халов Е.А. Систематический обзор четких одномерных функций принадлежности интеллектуальных систем // Информационные технологии и вычислительные системы. – 2009. – № 3.
- [Ivanov et al., 2022] Ivanov V.K., Palyukh B.V., Sotnikov A.N. Generation of Production Rules with Belief Functions to Train Fuzzy Neural Network in Diagnostic System // Lobachevskii Journal of Mathematics. – 2022. – No. 43 (10).
- [Yager et al., 2010] Yager R., Liping L. Classic Works of the Dempster-Shafer Theory of Belief Functions. – London, Springer Publ., 2010.
- [Ivanov et al., 2019] Ivanov V.K., Palyukh B.V., Sotnikov A.N. Evidence Theory for Complex Engineering System Analyses // Advances in Intelligent Systems and Computing. – 2019. – No. 874.
- [Иванов и др., 2019] Иванов В.К., Образцов И.В., Палюх Б.В. Реализация экспертной системы для оценки инновационности технических решений. Программные продукты и системы. – 2019. – № 26 (4).

- [**Ferson, 2002**] Ferson S., Sentsz K. Combination of evidence in Dempster-Shafer theory. Report SAND 2002-0835, Sandia National Laboratories, 2002.
- [**Лепский, 2021**] Лепский А.Е. Анализ противоречивости информации в теории функций доверия. Ч. 1. Внешний конфликт // Проблемы управления. – 2021. – № 5.
- [**Jang, 1993**] Jang J.-S.R. ANFIS: adaptive-network-based fuzzy inference system // IEEE Transactions on Systems, Man, and Cybernetics. – 1993. – No. 23 (3).
- [**Иванов и др., 2021**] Иванов В.К., Палюх Б.В. Демонстратор программной платформы для совместного использования алгоритмов теории свидетельств и нейронных сетей в нечетких системах // Программные продукты и системы. – 2021. – № 34 (4).
- [**Reineking, 2014**] Reineking T. A Python library for performing calculations in the Dempster-Shafer theory of evidence. – URL: <https://github.com/reineking/pyds> (дата обращения: 03.08.2022).
- [**Cuervo, 2022**] Cuervo S. A Tensorflow implementation of the Adaptive Neuro-Based Fuzzy Inference System (ANFIS). – URL: <https://github.com/tiagoCuervo/TensorANFIS> (дата обращения: 03.08.2022).
- [**Gregor, 2022**] Gregor G. An implementation of Adaptive-Network-Based Fuzzy Inference System (ANFIS) based on Keras on top of Tensorflow 2.0. – URL: <https://github.com/gregorLen/AnfisTensorflow2.0> (дата обращения: 03.08.2022).

УДК 004.8

МОДЕЛЬ СРЕДЫ ДЛЯ АКТОРА И КРИТИКА В ОБУЧЕНИИ С ПОДКРЕПЛЕНИЕМ

А.И. Панов (*pan@isa.ru*)

Федеральный исследовательский центр
«Информатика и управление» Российской академии наук, Москва;
Институт искусственного интеллекта AIRI, Москва

Л.А. Угадаров (*ulaelfray@gmail.com*)

Московский физико-технический институт
(Национальный исследовательский университет), Москва

Обучение с подкреплением с использованием модели среды является гибридным подходом, объединяющим планирование и безмодельное обучение, одним из главных преимуществ которого является высокая эффективность взаимодействия интеллектуального агента со средой при поиске оптимального поведения. Подходы, использующие модель среды, применяют её либо для дополнительного обучения стратегии на сгенерированных по модели траекториях, либо для получения более точной аппроксимации функции полезности состояний, с помощью которой оценивается полезность действий вдоль многошаговых модельных траекторий. В работе предлагается новый подход интеграции модели среды в качестве критика в архитектуры семейства актор-критик для оценки полезности действий. Эксперименты с гибридными алгоритмами, использующими модель среды с упреждающим поиском по дереву в качестве критика, на средах со сложным набором подцелей показали, что предлагаемая интеграция может ускорить обучение стратегии при определенных условиях.

Ключевые слова: обучение с подкреплением, модель среды, архитектура актор-критик, планирование поведения, упреждающий поиск по дереву.

Введение

Задачи последовательного принятия решений часто формализуются с помощью Марковского процесса принятия решений (МППР) [Puterman, 1994]. Если динамика среды неизвестна, то обычно такие задачи решаются с помощью подходов безмодельного обучения с подкреплением. При

известной динамике среды задача решается методами планирования. Промежуточным вариантом является обучение с подкреплением с использованием модели среды [Plaat, 2021], когда агент строит модель функций переходов и вознаграждения на основе опыта взаимодействия со средой. Применяя модель для вычисления следующего состояния и награды, агент осуществляет многошаговое планирование и выбор оптимального с точки зрения текущей модели действия, не взаимодействуя со средой [Панов, 2022б]. При высокой стоимости взаимодействий со средой это свойство имеет большое значение. Таким образом, при достаточно качественной модели среды, алгоритмы, использующие модель, оказываются эффективнее безмодельного обучения с подкреплением [Панов, 2022а].

Разработаны подходы, которые используют обученную модель динамики как в исходном пространстве состояний [Kaiser, 2020], так и в абстрактном пространстве [Hafner, 2018; Hafner, 2021; Zholus et al., 2022] для обучения безмодельных алгоритмов на модельных траекториях, полученных сэмплированием из вероятностной модели среды. В другой группе алгоритмов [Silver, 2017; Oh, 2017; Farquhar, 2018] вместе с моделью среды одновременно строится модель функции полезности состояний. В этом случае модель среды и модель функции полезности состояний используются вместе для планирования поведения с помощью многошаговой оценки полезности действий. Для обучения модели полезности состояний применяется Q-обучение.

В данной работе мы рассматриваем интеграцию безмодельных алгоритмов семейства актор-критик и алгоритмов, использующих модель среды для оценки полезности действий. Мы предложили использовать Q-сеть с упреждающим поиском по дереву (TreeQN) [Farquhar, 2018], предсказывающую полезность действий, в качестве критика в алгоритме усреднённого актор-критика (MAC) [Cameron, 2017] и в алгоритме оптимизации ближайшей стратегии (PPO) [Schulman, 2017].

Эксперименты с предлагаемыми алгоритмами проведены в среде Pong из популярного набора сред для оценки качества алгоритмов обучения с подкреплением Atari 2600 [Bellemare, 2012], а также в среде Crafter [Hafner, 2022], характерными особенностями которой являются необходимость глубокого исследования и принятия решений в условиях редкого и отложенного вознаграждения. Эмпирические результаты показывают, что интеграция MAC и TreeQN обучается быстрее, чем оригинальные алгоритмы MAC и TreeQN. Однако интеграции PPO и TreeQN демонстрирует ухудшение скорости обучения по сравнению с PPO и TreeQN. Такой результат может быть вызван достаточно медленным обучением модели функции полезности состояний из-за сложности предсказания скалярных значений полезности.

1. Метод

Марковский процесс принятия решений (МППР) [Sutton, 2018] для полностью наблюдаемой среды часто рассматривается в качестве математической модели для задач обучения с подкреплением. Формально он определяется как

$$U = (S, A, p, r, \gamma, S_{init}),$$

где S – пространство состояний среды, A – пространство действий агента, $p: S \times A \times S \rightarrow \mathbb{R}$ – функция переходов, $r: S \times A \times S \rightarrow \mathbb{R}$ – функция вознаграждения, $\gamma \in [0; 1]$ – дисконтирующий множитель, и $S_{init} \subseteq S$ – множество начальных состояний среды.

Эпизод начинается в состоянии $s_0 \sim S_{init}$. Каждый шаг t агент наблюдает текущее состояние среды s_t , на основе которого выбирает действие $a_t \sim \pi(\cdot | s_t, t)$, где $\pi: S \times A \rightarrow \mathbb{R}$ – стохастическая стратегия, определяющая условное распределение над пространством действий. Среда переходит в новое состояние $s_{t+1} \sim p(\cdot | s_t, a_t)$, а агент получает вознаграждение r_t , зависящее от результатов воздействия на среду: $r_t = r(s_t, a_t, s_{t+1})$. В результате эпизода подсчитывается отдача G_0 – дисконтированная сумма вознаграждений, полученных агентом во время эпизода, где $G_t = \sum_{i=t}^{i=T} \gamma^{i-t} r_i$. Функция полезности действий Q^π определена как математическое ожидание отдачи при выполнении действия a_t в состоянии s_t : $Q^\pi(s_t, a_t) = \mathbb{E}_{s_{t+1} \sim p(\cdot | s_t, a_t), a_{t+1} \sim \pi(\cdot | s_{t+1})} [G_t | s_t, a_t]$. Функция полезности состояний V^π определяется через функцию полезности действий Q^π : $V^\pi = \sum_{a \in A} \pi(a | s) Q^\pi(s, a)$. Целью обучения с подкреплением является формирование оптимальной стратегии π^* :

$$V^{\pi^*}(s) \geq V^\pi(s) \quad \forall \pi, \forall s \in S.$$

Широко применяемым подходом к решению задач обучения с подкреплением являются методы семейства актор-критик [Mnih, 2016; Schulman, 2017; Naarhoja, 2018], сочетающие в себе как построение стратегии, так и самой функции полезности. При этом компоненты, представляющие стратегию и функцию полезности, явным образом разделены. Компонент, аппроксимирующий стратегию, отвечает за выбор действия и называется актором. Критик аппроксимирует функцию полезности, таким образом оценивая действия, выбранные актором. В общем виде функция потерь модели актора с параметрами θ и энтропийной регуляризацией имеет вид:

$$\begin{cases} L_{actor}(\theta) = \log[\pi_\theta(s, a)]F \\ \theta^* = \operatorname{argmax}_\theta L_{actor}(\theta) + \alpha H(\pi_\theta(\cdot | s_t)), \end{cases}$$

$H(\pi_\theta(\cdot | s_t))$ – энтропия стратегии, $\alpha > 0$ – коэффициент, контролирующий вклад энтропии в функцию потерь. В качестве F может применяться оценка полезности действий $Q(s, a)$, TD -ошибки или функции преимущества $A(s, a)$. Критик с параметрами η обучается с использованием квадратичной функции потерь:

$$\left\{ \begin{array}{l} L_{critic}(\eta) = -(G^\lambda - Critic_\eta(s, a))^2 \\ \eta^* = \underset{\eta}{\operatorname{argmax}} L_{critic}(\eta) \end{array} \right. ,$$

G^λ – λ -отдача, а $Critic_\eta(s, a)$ – выход критика.

Модели актора и критика обучаются итеративно на подвыборках эпизодов взаимодействия со средой. Причём параметры моделей обновляются после каждой итерации.

Во многих практических задачах функции перехода и вознаграждения неизвестны, а агенту доступно лишь значение вознаграждения r_t , полученного после применения действия a_t в текущем состоянии s_t . В подходах безмодельного обучения оптимальная стратегия строится напрямую на основе данных, приобретённых при взаимодействии агента со средой. С другой стороны, на основе опыта взаимодействия со средой агент может построить модель среды, аппроксимирующую функцию переходов $P \approx p$ и функцию вознаграждения $R \approx r$, и применить её предсказания в качестве дополнительного сигнала для обучения стратегии. Схема обучения с использованием модели среды показана на рис. 1. При этом точность модели среды имеет решающее значение для поиска оптимальной стратегии: безошибочная модель позволяет получить оптимальную стратегию без взаимодействия агента со средой, однако требует большого количества шагов для глубокого исследования среды и сбора данных для обучения модели. Менее точную модель получить проще, но ошибочные предсказания ухудшают качество получаемой стратегии особенно при использовании многошаговых прогнозов, когда ошибки модели накапливаются.

Одним из возможных способов улучшения качества алгоритмов актор-критик является уточнение предсказаний критика. В этой работе мы используем в качестве критика вариант модели TreeQN, которая задействует модель динамики среды для построения функции полезности действий.

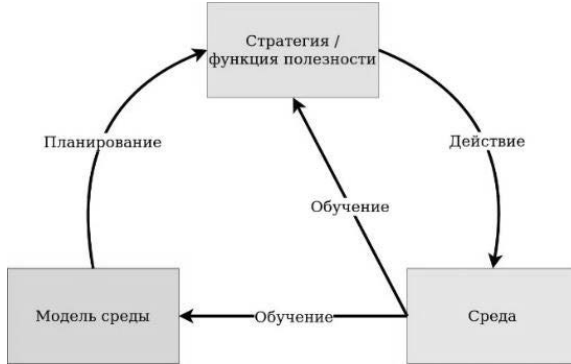


Рис. 1. Схема обучения с подкреплением с использованием модели среды

2. TreeQN

Нейросетевая модель TreeQN имеет рекурсивную структуру и используется для решения задач обучения с подкреплением с дискретным набором действий. TreeQN динамически строит дерево, рекурсивно применяя модель переходов в абстрактном пространстве состояний, и агрегирует предсказываемую награду и полезность состояний для оценки функции полезности действий. Схема работы алгоритма TreeQN изображена на рис. 2. Основными компонентами TreeQN являются:

- Кодировщик $encoder: S \rightarrow Z$, служащий для получения абстрактного представления состояний среды;
- Модель функции переходов $P: Z \times A \rightarrow Z$ в абстрактном пространстве состояний;
- Модель функции вознаграждения $R: Z \times A \rightarrow \mathbb{R}$;
- Модель функции полезности состояний $V: Z \rightarrow \mathbb{R}$.

Для текущего состояния среды $s_t \in S$ вычисляется его абстрактное представление $z_{0|t} = encoder(s_t)$ и путём рекурсивного применения модели переходов P динамически строится дерево последующих состояний $z_{l+1|t}^{a_i} = P(z_{l|t}, a_i)$ фиксированной глубины d для всех действий $a_i \in A$, где t – индекс шага в среде и $l < d$ – индекс шага планирования. Функция полезности действий в состоянии s_t оценивается как функция полезности корня дерева $Q^{TreeQN}(s_t, a) = Q^0(z_{0|t}, a)$ с использованием алгоритма $TD(\lambda)$ и -шаговых отдач, рассчитанных по дереву:

$$\begin{aligned}
Q^l(z_{l|t}, a_i) &= r(z_{l|t}, a_i) + \gamma V^{(\lambda)}(z_{l+1|t}) \\
V^{(\lambda)}(z_{l|t}) &= \begin{cases} V(z_{l|t}^{a_i}) & l = d \\ (1 - \lambda)V(z_{l|t}^{a_i}) + \lambda b(Q^{l+1}(z_{l+1|t}^{a_i}, a_j)) & l < d \end{cases} \\
b(\mathbf{x}) &= \sum_i x_i \text{softmax}(\mathbf{x})_i
\end{aligned}$$

Модель R выдаёт вознаграждения $r_{l|t}^a = R(z_{l|t}, a)$ вдоль путей из корня дерева в листовые вершины, а полезность состояний $z_{l|t}$ оценивается как усреднение предсказания модели $V(z_{l|t})$ с весом $1 - \lambda$ и softmax -агрегации полезности действий последующих состояний $z_{l+1|t}^{a_i}$ с весом λ . В качестве функции потерь используется квадрат отклонения предсказанных моделью значений полезности действий от n -шаговой отдачи в среде с применением замороженной версии сети для бутстрэпа.

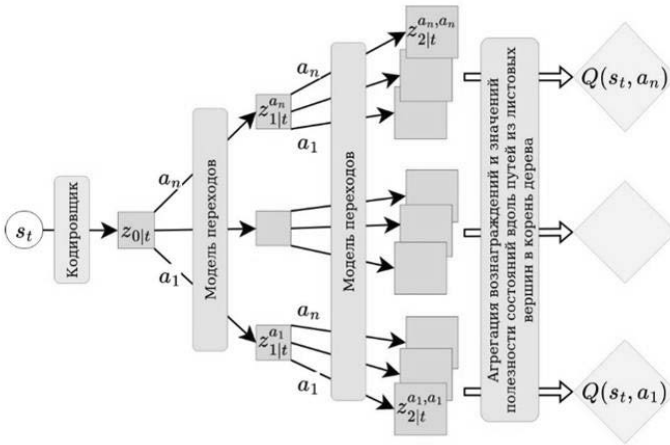


Рис. 2. Схема расчёта полезности действий в алгоритме TreeQN с глубиной $d = 2$

3. Интеграция TreeQN с алгоритмами семейства актор-критик

Предлагаемая интеграция заключается в использовании сети TreeQN в качестве критика. В качестве алгоритмов актор-критик для интеграции с TreeQN рассматриваются PPO и MAC.

3.1. Интеграция с алгоритмом PPO

Алгоритм PPO входит в семейство методов актор-критик. Основная идея алгоритма заключается в том, чтобы обновление стратегии во время обучения не приводило к ухудшению её качества. Актор аппроксимирует стратегию π_θ , критик – функцию полезности состояний V_η , где θ – параметры актора и η – параметры критика. Функции потерь для версии PPO с усечением в целевой функции актора имеют вид:

$$\begin{cases} L_{actor}(\theta) = \min[\rho_t(\theta)A_t, \text{clip}(\rho_t(\theta), 1 - \epsilon, 1 + \epsilon)A_t] \\ L_{critic}(s_t, \eta) = -\left(G^\lambda(s_t) - V_\eta(s_t)\right)^2 \end{cases},$$

t – индекс шага в среде; $G^\lambda(s_t)$ – λ -отдача; ρ_t – отношение вероятностей действий между новой и старой стратегиями; ϵ – параметр, контролирующий степень изменения стратегии на одном обновлении. Выход критика используется в обобщённой оценке функции преимущества в качестве предсказания базового уровня: $A_t = \delta_t + (\gamma\lambda)\delta_{t+1} + \dots + (\gamma\lambda)^{T-t+1}\delta_{T-1}$, где $\delta_t = r_t + \gamma V_\eta(s_{t+1}) - V_\eta(s_t)$.

Поскольку в PPO критик применяется для оценки полезности состояний, то модель TreeQN необходимо преобразовать в модуль, предсказывающий функцию полезности состояний. Для этого выдаваемые TreeQN значения полезности действий усредняются по текущей стратегии π_θ . При этом функция потерь критика не изменяется:

$$V_\eta^{TreeQN}(s_t) = \sum_{a \in A} \pi_\theta(a|s_t) Q_\eta^{TreeQN}(s_t, a).$$

Предполагая, что за счёт упреждающего поиска на несколько шагов вперёд TreeQN будет предсказывать базовый уровень более точно, чем многослойный перцептрон, который обычно используется для реализации критика в PPO, можно ожидать, что гибридный алгоритм PPO+TreeQN продемонстрирует качественный прирост.

3.2. Интеграция с алгоритмом MAC

Алгоритм MAC разработан для сред с дискретным пространством действий. Особенностью, которая отличает его от других алгоритмов семейства актор-критик, является то, что для оценки градиента стратегии используются оценки полезности всех действий, а не только тех, которые были выполнены при взаимодействии со средой. Актор аппроксимирует стратегию π_θ , критик – функцию полезности действий Q_η , где θ – параметры актора и η – параметры критика. Функции потерь для актора и критика:

$$\begin{cases} L_{actor}(\theta) = \sum_{a \in A} \pi_{\theta}(a|s_t) Q_{\eta}(s_t, a) \\ L_{critic}(\eta) = -(G^{\lambda}(s_t, a_t) - Q_{\eta}(s_t, a_t))^2 \end{cases}$$

t – индекс шага в среде; $G^{\lambda}(s_t, a_t)$ – λ -отдача.

Выходом критика является оценка значений функции полезности действий, которые подставляются в градиент стратегии. Таким образом можно напрямую задействовать TreeQN в качестве критика, не внося никаких изменений ни в MAC, ни в TreeQN. Как и в случае с PPO, мы ожидаем, что многошаговое прогнозирование уточнит предсказание функции полезности действий и ускорит обучение стратегии в гибридном алгоритме MAC+TreeQN по сравнению с оригинальной реализацией MAC, где используется многослойный персептрон.

4. Эксперименты

Работа гибридных алгоритмов PPO+TreeQN и MAC+TreeQN оценивалась в игровых средах Atari 2600 Pong и Crafter. Эксперименты были проведены с целью сравнения качества гибридных алгоритмов с оригинальными реализациями PPO и MAC, а также с такими алгоритмами, используемыми в качестве базового уровня в современных задачах, как безмодельные Rainbow [Hessel, 2018] и алгоритм асинхронной оптимизации ближайшей стратегии (APPO) [Petrenko, 2020] и использующие модель среды DreamerV2 [Hafner, 2021] и SimPLe [Kaiser, 2020].

Реализация гибридного алгоритма PPO+TreeQN основана на библиотеке stable-baselines3 [Raffin, 2021], а интеграция MAC+TreeQN использует собственную реализацию алгоритма MAC. Также для сравнения был реализован вариант PPO (large critic), у которого в качестве критика выступает четырёхслойный персептрон с количеством параметров, равным количеству параметров TreeQN.

4.1. Описание среды Pong

Atari 2600 Pong – это двухмерная спортивная видеоигра, имитирующая настольный теннис. По горизонтали игровое поле ограничено экраном, вертикальные границы выделены белыми полосами. Агент управляет левой ракеткой, правая ракетка контролируется встроенным алгоритмом. Ракетки двигаются по вертикали вверх и вниз. Мяч двигается по экрану по линейной траектории, отскакивает от ракеток, а также верхней и нижней границ игрового поля. Игровой раунд заканчивается, когда один из игроков не смог отбить мяч, и он пересёк вертикальную границу игрового поля. При этом счёт противника увеличивается на одно очко. При наборе одним из игроков 21 очка эпизод заканчивается.

4.2. Описание среды Crafter

Crafter [Hafner, 2022] представляет собой двухмерную видеоигру, упрощенную версию Minecraft [Skrynnik et al., 2021]. Целью агента является выживание в случайно сгенерированном мире. Для этого агенту необходимо добывать пищу и воду, находить убежище для сна, защищаться от монстров, собирать ресурсы и создавать инструменты. Карта мира – 64-клеточная квадратная область, каждая ячейка которой соответствует определённому типу местности. В поле зрения агента входит лишь 3 ячейки по вертикали и 4 по горизонтали. У агента есть уровни еды, воды и отдыха, которые снижаются со временем и восстанавливаются за счет питья из озера, сбора пищи и сна. Как только один из трех уровней достигает нуля, игрок начинает терять очки здоровья. Он также может терять очки здоровья при нападении зомби и скелетов. Когда очки здоровья достигают нуля, игрок умирает. Агент может собирать ресурсы и делать из них оружие или инструменты. Для сбора некоторых ресурсов, необходимо иметь инструменты, сделанные из других ресурсов. Например, для сбора камня агент должен обладать киркой, сделанной из дерева.

4.2.1. Наблюдения. Среда выдаёт цветное изображение размером 64x64. Изображение включает часть карты, которая попадает в поле зрения агента, а также содержимое инвентаря и текущие показатели уровня здоровья, пищи, воды и отдыха. Пример изображения показан на рис. 3.



Рис. 3. Наблюдение в среде Crafter. В центре расположен игровой персонаж. Внизу размещён инвентарь. В поле зрения находятся различные типы местности (трава, вода) и деревья. Агент может съесть корову, которая движется справа, для пополнения уровня пищи

4.2.2. Действия. Пространство действий состоит из 17 элементов: передвижение в четырёх направлениях, переход в режим сна, размещение объекта из инвентаря перед собой, создание инструмента, а также по одному действию на применение каждого типа объекта и инструмента.

4.2.3. Окончание эпизода. Эпизод заканчивается, если уровень здоровья игрока опустился до нуля или игрок сделал 10000 шагов.

4.2.4. Награда. В среде определены $N = 22$ достижения, соответствующие различным способностям агента: сбор различных ресурсов, пищи, воды, создание инструментов, уничтожение монстров и т.д. Некоторые достижения зависят от других, так образуется иерархия достижений. Агент получает награду +1 каждый раз, когда впервые выполняет достижение. Также он получает награду -0.1 за потерю одного очка здоровья и +0.1 за его восстановление. Таким образом наличие иерархии достижений требует от агента глубокого исследования среды и принятия решений в условиях редкого и отложенного вознаграждения.

4.2.3. Оценка эффективности агента. В качестве меры разнообразия способностей, выученных агентом, выбрана частота выполнения достижений [Hafner, 2022]: для каждого достижения вычисляется отношение количества эпизодов, в которых агент выполнил это достижение, к общему количеству эпизодов. Частоты выполнения всех достижений $\{f_i\}_{i=1}^N$ агрегируются в метрику *score* с помощью геометрического усреднения:

$$score = \exp\left(\frac{1}{N} \sum_{i=1}^N \ln(1 + f_i)\right) - 1, \text{ где } f_i \in [0; 100] \text{ и } N = 22.$$

5. Результаты

5.1. Эксперименты в среде Pong

В среде Pong проводились эксперименты со следующими вариантами алгоритмов: PPO+TreeQN: d=2 – интеграция PPO с TreeQN глубиной d=2; PPO+TreeQN: d=3 – интеграция PPO с TreeQN глубиной d=3; PPO (stable-baselines3) – реализация PPO в библиотеки stable-baselines3; MAC+TreeQN: d=2 – интеграция MAC с TreeQN глубиной d=2; MAC+TreeQN: Q-normalization – вариант интеграции MAC с TreeQN глубиной d=2 с нормализацией значений функции полезности действий; MAC+TreeQN: no-target-critic – вариант интеграции MAC с TreeQN глубиной d=2, в которой не используется замороженная сеть TreeQN для бутстрепа; MAC – реализация оригинального алгоритма MAC.

Графики скользящего среднего суммарной награды за эпизод представлены на рис. 4. Гибридные модели PPO+TreeQN обучаются медленнее, чем оригинальный алгоритм PPO (stable-baselines3), причём увеличение глубины предсказания не сказывается на качестве. С другой стороны, применение TreeQN в алгоритме MAC привело к значительному ускоре-

нию обучения. Дополнительный небольшой прирост удалось получить при отказе от использования замороженной версии критика для расчёта бутстрэп-оценки отдачи. Однако, обучение модели MAC+TreeQN происходит всё ещё значительно медленнее, чем PPO. Также в случае MAC+TreeQN заметный эффект даёт применение нормализации значений функции полезности действий по подвыборке опыта взаимодействия со средой, которая используется на данной итерации обучения: на раннем этапе до 1.5 млн шагов обучение ускоряется, но затем скорость обучения существенно падает. При этом значительно растёт дисперсия между запусками алгоритма.

5.2. Эксперименты в среде Crafter

В среде Crafter проводились эксперименты со следующими вариантами алгоритмов: DreamerV2 – оригинальная реализация алгоритма DreamerV2; Rainbow – оригинальная реализация алгоритма Rainbow; PPO+TreeQN: d=2 – интеграция PPO с TreeQN глубиной d=2; PPO (stable-baselines3) – реализация PPO в библиотеки stable-baselines3; TreeQN: d=2 – оригинальная реализация TreeQN глубиной d=2; PPO (large critic) – вариант PPO, у которого в качестве критика выступает четырёхслойный перцептрон с количеством параметров, равным количеству параметров TreeQN.; APPO – оригинальная реализация алгоритма APPO; SimPLe – оригинальная реализация алгоритма SimPLe; MAC+TreeQN – интеграция MAC с TreeQN глубиной d=2.



Рис. 4. График зависимости скользящего среднего суммарного вознаграждения за эпизод от количества шагов в среде Atari Pong. Произведено усреднение кривых по трём запускам алгоритмов. Затенение показывает минимальное и максимальное значение в группе запусков

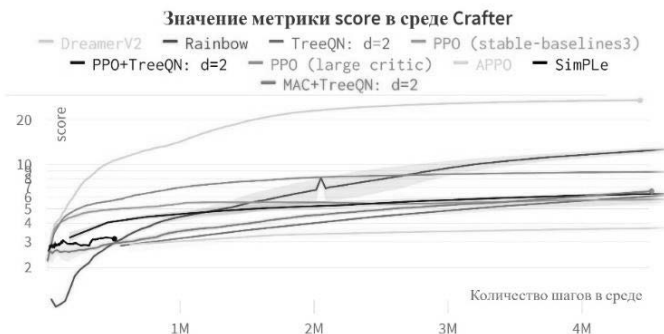


Рис. 5. Графики зависимости метрики score от количества шагов в среде Crafter для всех рассматриваемых алгоритмов с бюджетом взаимодействия со средой не более 4.5 млн шагов. Для оси ординат применён логарифмический масштаб. Произведено усреднение кривых по трём запускам алгоритмов. Затенение показывает минимальное и максимальное значение в группе запусков

Графики метрики **score** представлены на рис. 5 и 6, скользящего среднего суммарной награды за эпизод — на рис. 7 и 8. Стоит отметить, что ранжирование алгоритмов по обоим метрикам совпадает. Наименьшую скорость обучения показал алгоритм SimPLe, что, предположительно, связано с тем, что он оптимизирован для подмножества сред Atari в режиме малого взаимодействия со средой (не более 100000 шагов) и ему не хватает мощности для работы в такой сложной среде, как Crafter.

В среде Crafter гибридный алгоритм PPO+TreeQN превосходит оригинальный PPO (stable-baselines3), однако уступает варианту PPO (large critic), у которого критик имеет столько же параметров, что и TreeQN, но состоит только из четырёх полносвязных слоёв. TreeQN и интеграция MAC+TreeQN уступают PPO на начальном этапе до 4.5 млн шагов, но на 10 млн шагов уже опережают все варианты PPO и PPO+TreeQN. На отрезке до 120 млн шагов MAC+TreeQN демонстрирует более эффективное обучение, чем TreeQN. Медленнее всего обучается APPO, но к 100 млн шагов он уже превосходит все остальные алгоритмы. На начальном этапе до 4.5 млн шагов самое быстрое обучение демонстрируют Rainbow и DreamerV2, причём DreamerV2 значительно превосходит всё остальные алгоритмы, а APPO достигает таких результатов только к 70 млн шагов.

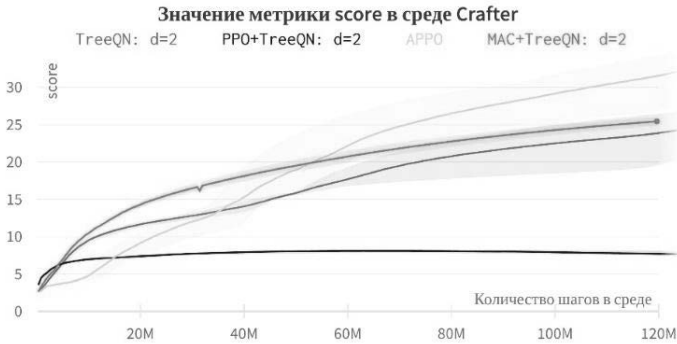


Рис. 6. Графики зависимости метрики score от количества шагов в среде Crafter для медленно обучающихся алгоритмов с бюджетом взаимодействия со средой не более 120 млн шагов. Произведено усреднение кривых по трём запускам алгоритмов. Затенение показывает минимальное и максимальное значение в группе запусков



Рис. 7. Графики зависимости скользящего среднего суммарного вознаграждения за эпизод от количества шагов в среде Crafter для всех рассматриваемых алгоритмов с бюджетом взаимодействия со средой не более 4.5 млн шагов. Произведено усреднение кривых по трём запускам алгоритмов. Затенение показывает минимальное и максимальное значение в группе запусков

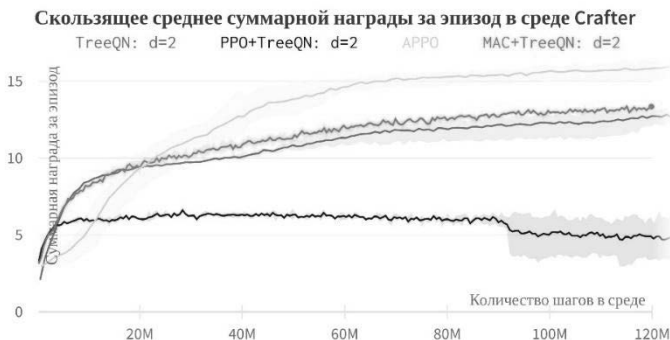


Рис. 8. Графики зависимости скользящего среднего суммарного вознаграждения за эпизод от количества шагов в среде Crafter для медленно обучающихся алгоритмов с бюджетом взаимодействия со средой не более 120 млн шагов. Произведено усреднение кривых по трём запускам алгоритмов. Затенение показывает минимальное и максимальное значение в группе запусков

Заключение

В работе представлены гибридные алгоритмы PPO+TreeQN и MAC+TreeQN, комбинирующий безмодельных алгоритмы семейства актор-критик и алгоритм, применяющий модель среды для оценки полезности действий. Эксперименты на средах Atari 2600 Pong и Crafter показали, что интеграция TreeQN в качестве критика в алгоритм MAC ускоряет обучение стратегии, а в случае интеграции с PPO происходит замедление обучения.

Гибридный алгоритм PPO+TreeQN демонстрирует ухудшение скорости обучения по сравнению с оригинальным алгоритмом PPO (stable-baselines3) в среде Pong и его вариантом PPO (large critic) в среде Crafter. Предположительно, это связано с медленным обучением TreeQN из-за сложности предсказания скалярных значений функции полезности. Поэтому усложнение критика в алгоритме PPO, который в оригинальной версии уже достаточно эффективен, лишь замедлило обучение.

С другой стороны, интеграция MAC+TreeQN обучается быстрее, чем оригинальные MAC и TreeQN. Можно сделать вывод, что суммирование оценок функции полезности действий при расчёте градиента стратегии в алгоритме MAC уменьшает влияние ошибок модели TreeQN. Также стоит отметить, что в среде Crafter алгоритм MAC+TreeQN превосходит APPO на первом этапе обучения (до 45 млн шагов по метрике и до 20 млн по суммарной награде за эпизод) и уступает лишь алгоритмам DreamerV2 и Rainbow.

Список литературы

- [Bellemare et al., 2012] Bellemare M. and Naddaf Y. and Veness J. and Bowling M. The Arcade Learning Environment: An Evaluation Platform for General Agents // Journal of Artificial Intelligence Research. – 2012. – No. 47.
- [Cameron et al., 2017] Allen C. and Asadi K. and Roderick M. and Mohamed A. and Konidaris G. and Littman M. Mean Actor Critic. – 2017. – URL: <https://arxiv.org/abs/1709.00503>.
- [Farquhar et al., 2018] Farquhar G. and Rocktaeschel T. and Igl M. and Whiteson S. TreeQN and ATreeC: Differentiable Tree Planning for Deep Reinforcement Learning // International Conference on Learning Representations. – 2018.
- [Haarnoja et al., 2018] Haarnoja T. and Zhou A. and Abbeel P. and Levine S. Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor // Proceedings of the 35th International Conference on Machine Learning. – 2018.
- [Hafner 2022] Hafner D. Benchmarking the Spectrum of Agent Capabilities // International Conference on Learning Representations. – 2022.
- [Hafner et al., 2018] Hafner D. and Lillicrap T. and Fischer I. and Villegas R. and Ha D. and Lee H. and Davidson J. Learning Latent Dynamics for Planning from Pixels // Proceedings of the 36th International Conference on Machine Learning. – 2018.
- [Hafner et al., 2021] Hafner D. and Lillicrap T. and Norouzi M. and Ba J. Mastering Atari with Discrete World Models // International Conference on Learning Representations. – 2021.
- [Hessel et al., 2018] Hessel M. and Modayil J. and Van Hasselt H. and Schaul T. and Ostrovski G. and Dabney W. and Horgan D. and Piot B. and Azar M. and Silver D. Rainbow: Combining improvements in deep reinforcement learning // Proceedings of the 32nd AAAI Conference on Artificial Intelligence and Thirtieth Innovative Applications of Artificial Intelligence Conference and Eighth AAAI Symposium on Educational Advances in Artificial Intelligence. – 2018.
- [Kaiser et al., 2020] Kaiser Ł. and Babaeizadeh M. and Miłoś P. and Osiański B. and Campbell R. and Czechowski K. and Erhan D. and Finn C. and Kozakowski P. and Levine S. and Mohiuddin A. and Sepassi R. and Tucker G. and Michalewski H. Model Based Reinforcement Learning for Atari // International Conference on Learning Representations. – 2020.
- [Mnih et al., 2016] Mnih V. and Badia A.P. and Mirza M. and Graves A. and Lillicrap T. and Harley T. and Silver D. and Kavukcuoglu K. Asynchronous Methods for Deep Reinforcement Learning // Proceedings of The 33rd International Conference on Machine Learning. – 2016.
- [Oh et al., 2017] Oh J. and Singh S. and Lee H. Value Prediction Network // Advances in Neural Information Processing Systems. – 2017. – No. 30.
- [Petrenko et al., 2020] Petrenko A. and Huang Z. and Kumar T. and Sukhatme G. and Koltun V. Sample Factory: Egocentric 3D Control from Pixels at 100000 FPS with Asynchronous Reinforcement Learning. // Proceedings of the 37th International Conference on Machine Learning. – 2020.

- [**Plaat et al., 2021**] Plaat A. and Kusters W. and Preuss M. High-Accuracy Model-Based Reinforcement Learning, a Survey. – 2021. – URL: <https://arxiv.org/abs/2107.08241>.
- [**Puterman 1994**] Puterman M.L. Markov Decision Processes: Discrete Stochastic Dynamic Programming. 1st. USA: John Wiley и Sons, Inc., 1994.
- [**Raffin et al., 2021**] Raffin A. and Hill A. and Gleave A. and Kanervisto A. and Ernestus M. and Dormann N. Stable-Baselines3: Reliable Reinforcement Learning Implementations // Journal of Machine Learning Research. – 2021. – No. 22 (268).
- [**Schulman et al., 2017**] Schulman J. and Wolski F. and Dhariwal P. and Radford A. and Klimov O. Proximal Policy Optimization Algorithms. – 2017. – URL: <https://arxiv.org/abs/1707.06347>.
- [**Skrynnik et al., 2021**] Skrynnik A. et al. Hierarchical Deep Q-Network from imperfect demonstrations in Minecraft // Cognitive Systems Research. – 2021. – Vol. 65. – P. 74-78.
- [**Silver et al., 2017**] Silver D. and van Hasselt H. and Hessel M. and Schaul T. and Guez A. and Harley T. and Dulac-Arnold G. and Reichert D. and Rabinowitz N. and Barreto A. and Degris T. The Predictron: End-to-End Learning and Planning // Proceedings of the 34th International Conference on Machine Learning. 2017.
- [**Sutton et al., 2018**] Sutton R.S. and Barto A.G. Reinforcement Learning: An Introduction. Cambridge, MA, USA: A Bradford Book, 2018.
- [**Zholus et al., 2022**] Zholus A., Panov A.I. Case-based Task Generalization in Model-based Reinforcement Learning // Artificial General Intelligence. AGI 2021. Lecture Notes in Computer Science / ed. Goertzel B., Iklé M., Potapov A. – Springer International Publishing, 2022. – Vol. 13154. – P. 344-354.
- [**Панов, 2022а**] Панов А.И. Иерархическая постановка задачи объектно-центричного обучения с подкреплением // Интегрированные модели и мягкие вычисления в искусственном интеллекте: Сборник научных трудов XI Международной научно-практической конференции (ИММВ-2022, Коломна, 16-19 мая 2022 г.). В 2-х т. 2022. – С. 248-256.
- [**Панов, 2022б**] Панов А.И. Одновременное планирование и обучение в иерархической системе управления когнитивным агентом // Автоматика и телемеханика. – 2022. – Т. 8, № 6. – С. 53-71.

МЕТОД ВЫВОДА ДЛЯ СИСТЕМ ТИПА МАМДАНИ С НЕСИНГЛТОННОЙ ФАЗЗИФИКАЦИЕЙ^{*1}

В.Г. Синюк (*vgsinuk@mail.ru*)

С.А. Каратач (*karatach1998@yandex.ru*)

БГТУ им. В.Г. Шухова, Белгород

В статье получен результат логического вывода для широко используемых нечетких систем типа Мамдани при несинглотонной фаззификации. Он достигнут на основании подхода с применением нечеткого значения истинности, что дало возможность свести задачу к полиномиальной вычислительной сложности и обобщить условия для логического вывода. С применением метода дефаззификации суммы центров получены соотношения выхода нечеткой системы для определенных функций принадлежности консеквента правил.

Ключевые слова: нечеткое значение истинности, вычислительная сложность, уровень срабатывания правила, метод дефаззификации суммы центров.

Введение

Нечеткие системы рассматриваются как композиция фаззификатора, базы знаний, модуля вывода и дефаззификатора. Разнообразные комбинации методов вывода, фаззификации и дефаззификации приводят к многочисленным конструкциям нечетких систем. Наиболее популярная база знаний получена из первых исследований Мамдани [Mamdani, 1974], где как в антецедентной, так и в консеквентной частях правил используются нечеткие множества. Эта форма эволюционирует до формы типа Такаги-Сугено [Takagi et al., 1985], где в консеквентной части правил нечеткие множества заменяются четкими функциями.

В последнее время при разработке нечетких систем уделяется внимание изменению метода фаззификации. Фаззификация – это отображение из точки входного пространства в нечеткое множество. Основным методом явля-

* Работа выполнена при финансовой поддержке РФФИ (проект № 20-07-00030).

ется синглтонная фаззификация [Рутковский и др., 2010]. Она обычно применяется всегда при любом характере входных данных. Основным преимуществом такого подхода является существенное упрощение реализации методов вывода нечетких систем, особенно для нейро-нечетких систем. Альтернативным решением является несинглтонная (NS) фаззификация [Pourabdollah et al., 2017; Fu et al., 2018; Mendel et al., 2021].

NS-фаззификация используется в нечетких системах на основе правил, когда измерения, которые их активируют, несовершенны или неопределенны (из-за шума измерений, дефектов или ухудшения качества датчиков и т.д.), или когда их входными данными являются слова (как при вычислениях со словами). Она моделирует такие измерения или слова нечеткими числами или более общими нечеткими множествами, так что, независимо от причины несовершенства или неопределенности измерения или слова, они рассматриваются в рамках нечетких множеств и систем.

Фаззификация NS была введена и исследована для нечетких систем типа Мамдани и Такаги-Сугено в частном случае в [Mendel et al., 2021; Mendel et al., 2017; Mouzouris et al., 1997]. Данная статья посвящена развитию данного подхода для более общей постановки задачи. Проблема состоит в том, что в этом случае для нечетких систем MISO-структуры реализация нечеткого вывода с использованием известных методов приводит к экспоненциальной вычислительной сложности. В статье рассмотрены методы вывода на основе нечеткого значения истинности, снижающего вычислительную сложность до полиномиальной.

В разделе 1 осуществлена постановка задачи и оценка сложности при NS-фаззификации нечеткими числами при традиционном подходе. В разделе 2 представлены методы вывода для нечетких систем Мамдани с применением нечеткого значения истинности, что позволило снизить вычислительную сложность до полиномиальной и обобщить задачу вывода при NS-фаззификации. Раздел 3 посвящен применению метода дефаззификации суммы центров к результатам, полученным в разделе 2.

1. Постановка задачи

Лингвистическая модель представляет собой базу нечетких правил R_k , $k = \overline{1, N}$ вида:

$$R_k : \text{Если } x_1 \text{ есть } A_{1k} \text{ и } x_2 \text{ есть } A_{2k} \text{ и } \dots \text{ и } x_n \text{ есть } A_{nk}, \text{ то } u \text{ есть } B_k, \quad (1.1)$$

где N – количество нечетких правил, $A_{ik} \subseteq X_i$, $i = \overline{1, N}$, $B_k \subseteq Y$ – нечеткие множества, которые характеризуются функциями принадлежности $\mu_{A_{ik}}(x_i)$ и $\mu_{B_k}(y)$ соответственно; x_1, x_2, \dots, x_n – входные переменные лингвистической модели, причем

$$[x_1, x_2, \dots, x_n]^T = \mathbf{x} \in X_1 \times X_2 \times \dots \times X_n.$$

Символами X_i , $i = \overline{1, n}$ и Y обозначаются соответственно пространства входных и выходной переменных. Если ввести обозначения $\mathbf{X} = X_1 \times X_2 \times \dots \times X_n$ и $\mathbf{A}_k = A_{1k} \times A_{2k} \times \dots \times A_{nk}$, причем

$$\mu_{\mathbf{A}_k}(\mathbf{x}) = T_{\perp} \mu_{A_{ik}}(x_i),$$

где T_1 – произвольная t-норма, то правило (1.1) представляется в виде нечеткой импликации

$$R_k : \mathbf{A}_k \rightarrow B_k, \quad k = \overline{1, N}.$$

Правило R_k можно формализовать как нечеткое отношение, определенное на множестве $\mathbf{X} \times Y$, т.е. $R_k \subseteq \mathbf{X} \times Y$ – нечеткое множество с функцией принадлежности

$$\mu_{R_k}(\mathbf{x}, y) = \mu_{\mathbf{A}_k \rightarrow B_k}(\mathbf{x}, y).$$

Модель Мамдани определяет задание функции $\mu_{\mathbf{A}_k \rightarrow B_k}(\mathbf{x}, y)$ на основе известных функций принадлежности $\mu_{\mathbf{A}_k}(\mathbf{x})$ и $\mu_{B_k}(y)$ следующим образом [Рутковский и др., 2010; Пегат и др., 2009]:

$$\mu_{\mathbf{A}_k \rightarrow B_k}(\mathbf{x}, y) = T_2(\mu_{\mathbf{A}_k}(\mathbf{x}), \mu_{B_k}(y)) = \mu_{\mathbf{A}_k}(\mathbf{x}) \overset{T_2}{*} \mu_{B_k}(y),$$

где T_2 – произвольная t-норма.

Ставится задача определить нечеткий вывод $B'_k \subseteq Y$ для системы, представленной в виде (1.1), если на входах – нечеткие множества $A' = A'_1 \times A'_2 \times \dots \times A'_n \subseteq \mathbf{X}$ или x_1 есть A'_1 и x_2 есть A'_2 и ... и x_n есть A'_n с соответствующей функцией принадлежности $\mu_{A'}(\mathbf{x})$, которая определяется как

$$\mu_{A'}(\mathbf{x}) = T_{\perp} \mu_{A'_i}(x_i). \quad (1.2)$$

Несингтонный фаззификатор отображает измеренное $x_i = x'_i$, $i = \overline{1, n}$ в нечеткое число, для которого $\mu_{A'_i}(x'_i) = 1$ и $\mu_{A'_i}(x_i)$ уменьшается от единицы по мере удаления от x'_i .

Концептуально [Mouzouris et al., 1997] NS фаззификация подразумевает, что данное входное значение x'_i есть значение, которое будет наиболее возможным из всех значений, находящихся рядом; однако, так как вход является неопределенным, соседние значения также могут быть возможными, но в меньшей степени.

В соответствии с обобщенным нечетким правилом *modus ponens* [Рутковский и др., 2010], нечеткое множество B'_k определяется композицией нечеткого множества A' и отношения R_k , т.е.

$$B'_k = A' \circ (A_k \rightarrow B_k),$$

или, на уровне функций принадлежности,

$$\mu_{B'_k}(y | \mathbf{x}') = \sup_{x \in X} \left\{ \mu_{A'}(\mathbf{x}) \overset{T_4}{*} \left(\mu_{A_k}(\mathbf{x}) \overset{T_2}{*} \mu_{B_k}(y) \right) \right\}, \quad (1.3)$$

где T_2 может быть любым оператором в классе t-норм.

В (1.3) применена условная нотация, так как ввод в нечеткую систему происходит при определенном значении \mathbf{x} , а именно \mathbf{x}' . Обозначение $\mu_{B'_k}(y | \mathbf{x}')$ показывает, что $\mu_{B'_k}$ изменяется с каждым значением \mathbf{x}' . Вычислительная сложность выражения (1.3) составляет $O(|X_1| \cdot |X_2| \cdot \dots \cdot |X_n| \cdot |Y|)$.

2. Метод вывода с использованием нечеткого значения истинности (нзи)

Для снижения экспоненциальной сложности (1.3) рассмотрим следующие методы вывода.

2.1. Метод вывода, когда t-нормы различны

Применяя правило истинностной модификации [Борисов и др., 1990]

$$\mu_{A'}(\mathbf{x}) = \tau_{A_k|A'}(\mu_{A_k}(\mathbf{x})),$$

где $\tau_{A_k|A'}(\cdot)$ – нечеткое значение истинности (нзи) нечеткого множества A_k относительно A' , представляющее собой функцию принадлежности совместимости $CP(A_k, A')$ A_k по отношению к A' , причем A' рассматривается как достоверное [Добуа и др., 1990]:

$$\tau_{A_k|A'}(v) = \mu_{CP(A_k, A')}(v) = \sup_{\substack{\mu_{A_k}(x)=v \\ x \in X}} \{ \mu_{A'}(x) \},$$

перейдем от переменной x к переменной v , обозначив $\mu_{A_k}(x) = v$. Получим:

$$\mu_{A'}(x) = \tau_{A_k|A'}(\mu_{A_k}(x)) = \tau_{A_k|A'}(v), \quad (2.1)$$

тогда (1.3) примет вид:

$$\mu_{B'_k}(y|x') = \sup_{v \in [0;1]} \{ \tau_{A_k|A'}(v) \overset{T_4}{*} (v \overset{T_2}{*} \mu_{B_k}(y)) \}. \quad (2.2)$$

При вербализации «инженерной» импликации в (2.2) она представится в виде:

$$\text{Если } n_{zi} \text{ есть истинно, то } y \text{ есть } B'_k. \quad (2.3)$$

Таким образом, (2.3) представляет собой еще одну структуру правил в отличие от канонических структур Заде [Zadeh, 1973] и Такаги-Сугено [Takagi et al., 1985]. Применение данного правила не зависит от количества входов в нечетких системах.

Выражение (2.2) характеризуется сложностью порядка $O(|v| \cdot |Y|)$. Как следует из [Синюк и др., 2018; Sinuk et al., 2016]:

$$\begin{aligned} \mu_{CP(A_k, A')}(v) &= \tilde{T}_1 \mu_{CP(A_{k_1}, A'_1)}(v_1) = \\ &= (\dots ((\mu_{CP(A_{k_1}, A'_1)}(v_1) \tilde{T}_1 \mu_{CP(A_{k_2}, A'_2)}(v_2)) \tilde{T}_1 \mu_{CP(A_{k_3}, A'_3)}(v_3)) \tilde{T}_1 \dots) \tilde{T}_1 \mu_{CP(A_{k_n}, A'_n)}(v_n), \end{aligned}$$

где \tilde{T}_1 – расширенная по принципу обобщения n -местная t -норма и

$$\mu_{CP(A_{k_i}, A'_i)}(v_i) = \sup_{\substack{\mu_{A_{k_i}}(x_i)=v_i \\ x_i \in X_i}} \{ \mu_{A'_i}(x_i) \}.$$

Например, двухместная расширенная t -норма имеет вид:

$$\mu_{CP(A_k, A')}(v) = \tilde{T}_1 \mu_{CP(A_{k_1}, A'_1)}(v_1) = \sup_{\substack{v_1 \tilde{T}_1 v_2 = v \\ (v_1, v_2) \in [0;1]^2}} \{ \mu_{CP(A_{k_1}, A'_1)}(v_1) \tilde{T}_3 \mu_{CP(A_{k_2}, A'_2)}(v_2) \}.$$

Последнее соотношение характеризуется сложностью порядка $O(|v|^2)$.

2.2. Метод вывода, если $T_4 = T_2 = T$

С учетом свойства ассоциативности t-норм выражение (2.2) примет вид:

$$\begin{aligned}\mu_{B'_k}(y | \mathbf{x}') &= \sup_{v \in [0;1]} \left\{ \tau_{A_k | A'}(v) \overset{T}{*} \left(v \overset{T}{*} \mu_{B_k}(y) \right) \right\} = \sup_{v \in [0;1]} \left\{ \left(\tau_{A_k | A'}(v) \overset{T}{*} v \right) \overset{T}{*} \mu_{B_k}(y) \right\} = \\ &= \sup_{v \in [0;1]} \left\{ \tau_{A_k | A'}(v) \overset{T}{*} v \right\} \overset{T}{*} \mu_{B_k}(y) = \Pi_{A_k | A'} \overset{T}{*} \mu_{B_k}(y),\end{aligned}\quad (2.4)$$

где

$$\Pi_{A_k | A'} = \sup_{v \in [0;1]} \left\{ \tau_{A_k | A'}(v) \overset{T}{*} v \right\}$$

есть скалярная величина, которая является мерой возможности [Dubois et al., 2007], т.е. насколько antecedent правила A_k соответствует входам A' . Возможность, введенная в [Добуа и др., 1990], здесь определяется как мера совместимости полученного значения *нзи* (2.1) со значением *нзи* <истинно>.

Как следует из [Mendel et al., 2017], $\Pi_{A_k | A'} \in [0;1]$ есть уровень срабатывания (firing level) правила R_k , который меняется с каждым значением \mathbf{x}' .

Таким образом, применение нечеткого значения истинности при методе вывода (2.4) получен при различных T_1 , T_3 и $T = T_2 = T_4$. Данный результат обобщает результат, полученный в [Mendel et al., 2017; Mouzouris et al., 1997], когда имеет место ограничение на равенство всех t-норм.

3. Дефаззификация по методу суммы центров (Center of Sums, CoS)

Выходное значение нечеткой системы при CoS с учетом (2.4) определяется [Рутковский и др., 2010]:

$$\bar{y}_{CoS}(\mathbf{x}') = \frac{\int_Y y \sum_{k=1, N} \mu_{B_k}(y | \mathbf{x}') dy}{\int_Y \sum_{k=1, N} \mu_{B_k}(y | \mathbf{x}') dy} = \frac{\int_Y y \sum_{k=1, N} \Pi_{A_k | A'} \overset{T}{*} \mu_{B_k}(y) dy}{\int_Y \sum_{k=1, N} \Pi_{A_k | A'} \overset{T}{*} \mu_{B_k}(y) dy} \quad (3.1)$$

Утверждение

Вывод системы нечеткой логики с базой правил (1.1), с несинглтонным фаззификатором (1.2), дефаззификатором CoS, t-нормой Ларсена и при функциях принадлежности консеквента типа гауссовых и треугольных зависит от параметров этих функций как *точечных*, так и параметров *ширины*.

Доказательство

Применим в качестве t-нормы произведение (t-норма Ларсена), тогда (3.1) переписывается:

$$\bar{y}_{CoS}(\mathbf{x}') = \frac{\sum_{k=1, \overline{N}} \Pi_{A_k|A'} \int_Y y \mu_{B_k}(y) dy}{\sum_{k=1, \overline{N}} \Pi_{A_k|A'} \int_Y \mu_{B_k}(y) dy} \quad (3.2)$$

В качестве $\mu_{B_k}(y)$ используем гауссову функцию принадлежности

$$\mu_{B_k}(y) = \exp \left[- \left(\frac{y - \bar{y}_k}{\sigma_k} \right)^2 \right], k = \overline{1, N}, \quad (3.3)$$

где \bar{y}_k и σ_k – параметры *центра* и *ширины* функции принадлежности.

Для (3.3) известно, что [Пегат и др., 2009]:

$$\int_{-\infty}^{\infty} \mu_{B_k}(y) dy = \sigma_k \sqrt{\pi}$$

и

$$\int_{-\infty}^{\infty} y \mu_{B_k}(y) dy = \bar{y}_k \sigma_k \sqrt{\pi}. \quad (3.4)$$

С учетом (3.4) соотношение (3.2) принимает вид:

$$\bar{y}_{CoS}(\mathbf{x}') = \frac{\sum_{k=1, \overline{N}} \Pi_{A_k|A'} \bar{y}_k \sigma_k}{\sum_{k=1, \overline{N}} \Pi_{A_k|A'} \sigma_k}. \quad (3.5)$$

Данный подход можно рассмотреть если функции принадлежности B_k являются треугольными функциями т.е.:

$$\mu_{B_k}(y) = \begin{cases} 1 - \frac{2|y - \bar{y}_k|}{s_k}, & \text{если } |y - \bar{y}_k| \leq s_k / 2, k = \overline{1, N}, \\ 0, & \text{иначе} \end{cases} \quad (3.6)$$

где \bar{y}_k и s_k – параметры *центра* и *ширины* треугольной функции принадлежности.

Для (3.6) следует, что:

$$\int_{-\infty}^{\infty} \mu_{B_k}(y) dy = \frac{1}{2} s_k$$

и

$$\int_{-\infty}^{\infty} y \mu_{B_k}(y) dy = \frac{1}{2} \bar{y}_k s_k . \quad (3.7)$$

Тогда (3.2), учитывая (3.7), приобретает вид:

$$\bar{y}_{CoS}(\mathbf{x}') = \frac{\sum_{k=1, N} \Pi_{A_k|A'} \bar{y}_k s_k}{\sum_{k=1, N} \Pi_{A_k|A'} s_k} . \quad (3.8)$$




Рис. 1. Сетевая структура на основе метода дефаззификации CoS в соответствии выражения (3.4)

Сетевая структура, следуя соотношению (3.5), проиллюстрирована на рис.1. Первый уровень этой сетевой структуры определяет несингтонную фаззификацию, второй – вычисление *нзи* нечеткого множества $A_k, k=1, N$ относительно A' , на третьем уровне происходит вычисление возможности $\Pi_{A_k|A'}$, т. е. насколько antecedent A_k соответствует входам A' . Четвертый и пятый уровень осуществляет определение выходного значения нечеткой системы (1.1) y .

Сетевая структура соответствующая соотношению (3.8) такая как на рис. 1, но $\sigma_k, k=1, N$ заменяется в третьем слое на s_k .

Заключение

Предложенный метод вывода для нечетких систем типа Мамдани дает возможность применить его при несинглетонной фаззификации с полиномиальной вычислительной сложностью. Эти результаты получены, используя подход, основанный на нечетком значении истинности.

Следствием этого подхода является также новая структура лингвистических правил (2.3). Доказано утверждение, что при t-норме Ларсена, вывод на основе метода дефаззификации CoS учитывает параметры *ширины* гауссовской и треугольной функции принадлежности консеквента, в то время как ее аналог, основанный на дефаззификации по среднему центру включает только параметры *центра* [Синюк и др., 2022].

Список литературы

- [Борисов и др., 1990] Борисов А.Н., Крунберг О.А., Федоров И.П. Принятие решений на основе нечетких моделей. – Рига: Зинатне, 1990.
- [Добуа и др., 1990] Добуа Д., Прад А. Теория возможностей. Приложение к представлению знаний в информатике. – М.: Радио и связь, 1990.
- [Пегат и др., 2009] Пегат А. Нечеткое моделирование и управление // Лаборатория знаний. – М.: БИНОМ, 2009.
- [Рутковский и др., 2010] Рутковский Л. Методы и технологии искусственного интеллекта. – М.: Горячая линия – Телеком, 2010.
- [Синюк и др., 2018] Синюк В.Г., Михелев В.В. Методы вывода для систем логического типа на основе нечеткой степени истинности // Известия РАН. Теория и системы управления. – 2018. – № 3.
- [Синюк и др., 2022] Синюк В.Г., Кулабухов С.В. Методы вывода для систем типа Мамдани и Такаги-Сугено с несинглетонной фазификацией на основе нечеткого значения истинности // Интегрированные модели и мягкие вычисления в искусственном интеллекте. Сборник научных трудов XI Международной научно-практической конференции (ИММВ-2022, Коломна, 16-19 мая 2022 г.). В 2-х т. Т.1. – М.: РАИИ, 2022.
- [Dubois et al., 2007] Dubois D., Esteva F., Godo L., Prade H. Fuzzy-set Based Logics - An History-Oriented Presentation of Their Main Developments // The Many Valued and Nonmonotonic Turn in Logic. – Elsevier, 2007. – Vol. 8.
- [Fu et al., 2018] Fu C., Sarabakha A., Kayacan E., Wagner C., John R., Garibaldi J.M. Input Uncertainty Sensitivity Enhanced Nonsingleton Fuzzy Logic Controllers for Long-Term Navigation of Quadrotor UAVs // IEEE-ASME Transactions on Mechatronics. – 2018. – Vol. 23, No. 2.
- [Mamdani, 1974] Mamdani E.H. Applications of Fuzzy Algorithm for Control a Simple Dynamic Plant // Proc. IEEE. – 1974. Vol. 121, No. 12.
- [Mendel et al., 2017] Mendel J.M. Uncertain Rule-Based Fuzzy Systems: Introduction and New Directions. Second edition. – Cham, Switzerland: Springer, 2017.

- [**Mendel et al., 2021**] Mendel J.M. Non-Singleton Fuzzification Made Simpler // Information Sciences. – 2021. – Vol. 559.
- [**Mouzouris et al., 1997**] Mouzouris G.C., Mendel J.M. Non-Singleton Fuzzy Logic Systems: Theory and Application // IEEE Transactions on Fuzzy Systems. – 1997. – Vol. 5, No. 1.
- [**Pourabdollah et al., 2017**] Pourabdollah A., John R., Garibaldi J. M. A new dynamic approach for nonsingleton fuzzification in noisy time-series prediction // Proc. of FUZZ-IEEE. – 2017.
- [**Sinuk et al., 2016**] Sinuk V.G., Polyakov V.M., Kutsenko D.A. New Fuzzy Truth Value Based Inference Methods for Non-singleton MISO Rule-Based Systems // Proceedings of the First International Scientific Conference “Intelligent Information Technologies for Industry” (IITI '16). – 2016.
- [**Takagi et al., 1985**] Takagi T., Sugeno M. Fuzzy Identification of Systems and Its Application to Modeling and Control // IEEE Transactions on Systems, Man and Cybernetics. – 1985. – Vol. 15, No. 1.
- [**Zadeh, 1973**] Zadeh L.A. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes // IEEE Transactions on Systems, Man and Cybernetics. – 1973. – Vol. 3, No. 1.

УДК 681.5.015.2

ПРИМЕНЕНИЕ ОПТИМАЛЬНОГО АДАПТИВНОГО ОБОБЩЕННОГО ПРОГНОЗИРУЮЩЕГО УПРАВЛЕНИЯ К СУШКЕ ЗЕЛЕННОГО ЧАЯ*

К.Б. Фам

П.М. Мурашев

В.Н. Богатиков (*phambang79520897405@gmail.com*)

Тверской государственный технический университет, Тверь

Одной из наиболее часто используемых операций в перерабатывающей промышленности является сушка пищевых продуктов. Это сложная, многопараметрическая, нелинейная динамическая система, степень нелинейности которой определяется рабочим диапазоном процесса сушки. Чтобы сушилка работала эффективно, она должна быть не только хорошо спроектирована, но и реализованные стратегии управления также должны быть эффективными. Система управления процессом сушки должна поддерживать необходимые значения контролируемых переменных, отклонения которых при работе технологических процессов объясняются как неопределенностью условий процесса сушки, обусловленной наличием случайных возмущений, так и неопределенность знаний о физических и химических процессах. С целью повышения качества управления в условиях неопределенности в работе были применены методологии проектирования, основанные на использовании прогнозирующего контроллера состояния параметров системы с использованием метода оптимизации Бокса-Уилсона и методики «планирование эксперимента». Результаты моделирования системы управления процессом сушки зеленого чая показывают, что управление с прогнозирующими моделями (УПМ)-регулятор стабилен и устойчив с точки зрения подавления входных возмущений. При внедрении метода Бокса-Уилсона для модели объекта система управления УПМ относительно обеспечивает более эффективную работу по сравнению с традиционными УПМ.

Ключевые слова: сушка зеленого чая, обобщенное прогнозирующее управление (ОУП), метод Бокса-Уилсона, нечеткие модели.

* Работа выполнена при финансовой поддержке РФФИ, проект № 20-07-00914.

Введение

Чай является вторым наиболее потребляемым напитком (кроме воды) в мире и широко культивируется в Китае, Индии и других регионах. Доказано, что зеленый чай снижает заболеваемость хроническими патологиями, такими как [1] и сердечно-сосудистыми заболеваниями. Содержание влаги является важным фактором, влияющим на качество чая. Чрезмерное содержание влаги в чае ускоряет рост плесени [2]. Было предложено несколько исследований взаимосвязи между содержанием влаги в чае и качеством чая. В работе [3] показали, что чрезмерное увядание чая приводит к значительному снижению содержания влаги и ингибирует активность полифенолоксидазы. И в [3] обнаружили, что снижение содержания влаги привело к значительным изменениям в транскрипции генов и концентрации ароматизирующих соединений чая, что усилило отличительный вкус различных чаев. Поэтому точный контроль содержания влаги в чае тесно связан с качеством чая, что имеет большое значение в производстве чая. В настоящее время контроль содержания влаги в чае основывается на опыте рабочих, который очень субъективен. Кроме того, трудно гарантировать стабильность конечного содержания влаги в чае.

Управление процессом сушки является сложной задачей вследствие многих факторов, таких как нелинейность, неопределенность процесса и неточность математической модели. Чтобы сушилка работала эффективно, она должна быть не только хорошо спроектирована, но и реализованные стратегии управления также должны быть эффективными. Система управления процессом сушки должна поддерживать требуемые значения контролируемых переменных в условиях множества возмущений, возникающих в производственных ситуациях, и неопределенности условий процесса сушки. Многие исследования показали, что способность прогнозировать поведение процесса и определять на этой основе управляющие воздействия играют важную роль в качестве управления процессом. С целью повышения качества управления в условиях неопределенности процесса сушки в статье рассмотрены методологии проектирования, основанные на использовании прогнозирующего контроллера состояния параметров системы с использованием метода оптимизации Бокса-Уилсона и методики «планирование эксперимента».

1. Стратегия управления процессом термической обработки

Основная задача управления процессом сушки заключается в поддержании заданной температуры сушильного материала в условиях неопределенности внутренних и внешних возмущений, управлении движением конвейерной ленты для обеспечения необходимого содержания влаги в

чайных листьях, не допуская их пересушивания (что увеличивает затраты энергии и может привести к тепловому повреждению термочувствительных твердых веществ) и стабилизации всего процесса.

К основным критериям оптимизации процесса сушки зеленого чая относятся качество конечного продукта (конечная влажность зеленого чая), удельные энергозатраты (на единицу массы испаренной влаги) и время сушки зеленого чая. При конвекционной сушке эти параметры зависят от температуры сушильной камеры и скорости движения сушильного конвейера. Поэтому задача контроллера сушки зеленого чая заключается в управлении нагревателем, быстрое нагревание слоя зеленого чая до заданной температуры и дальнейшее ее поддержание в течение всего процесса, и в контроле скорости движения слой зеленого чая в сушильной камере.

Распространенный метод управления процессами заключается в применении нескольких предположительно независимых контуров управления с обратной связью. Регулируемые параметры контроллера встроены в систему управления технологическим процессом для повышения производительности процесса в широком диапазоне условий.

Пропорциональный (П), Пропорционально-интегрально-дифференцирующий (ПИД) и Пропорционально-интегральный (ПИ) регуляторы до сих пор являются наиболее часто применяемыми регуляторами промышленных процессов. Это в основном связано с простотой эксплуатации, надежностью и отсутствием специальных знаний о процессах, необходимых для первоначального проектирования контроллера. Контроллер, обеспечивающий наилучшую производительность, можно выбрать путем тестирования альтернативных комбинаций П-, ПИ- и ПИД-регулятора. Как правило, встречались и применялись три формы самонастраивающегося управления. Это самонастраивающееся ПИД-регулирование (СаПИД), обобщенное управление минимальной дисперсией (ОУМД) и обобщенное прогнозирующее управление (ОПУ). Применение систем управления СаПИД и ОУМД недавно было изучено некоторыми исследователями [4,5]. Оптимальное адаптивное обобщенное прогностическое управление (ОА-ОПУ) означает поддержание сушки в оптимальных условиях, а ОПУ также обеспечивает стабильный отклик с обратной связью, который минимизирует некоторую квадратичную целевую функцию. Считается, что ОА-ОПУ превосходит классические системы управления. Этот метод отступающего горизонта предсказывает выход объекта за несколько интервалов выборки, используя предположения о будущих управляющих воздействиях [6]. С помощью ОПУ можно получить устойчивое управление процессами с переменными параметрами, с переменным запаздыванием при условии, что входных-выходных данных достаточно для обоснованной идентификации объекта.

Соответствующая работа доступна в ранее опубликованной статье о той же системе сушки зеленого чая [7]. В данной работе был проведен анализ динамики процесса сушки зеленого чая. Достоверность модели осушения листьев зеленого чая в конвейерной сушилке исследована путем сравнения экспериментальных данных. Показано, что программа динамического моделирования может быть использована при проектировании системы ОПУ для контроля температуры и конечной влажности слоя зеленого чая.

Целью данной работы является исследование оценки внедрения метода Бокса-Уилсона, основанного на методике «планирование эксперимента» в процесс управления технологическим процессом сушки зеленого чая. Температура сушильного агента и скорость ленты сушилки были выбраны как очень эффективные параметры, влияющие на качество зеленого чая. В экспериментальной схеме целевая функция состоит в том, чтобы достигнуть желаемого значения влажности выпускного слоя зеленого чая (3-5%), и поддерживать температуру и состав исходного сырья, тепловую нагрузку сушилки и расход нагревательного слоя зеленого чая путем определения оптимальных значения температуры сушильного агента и скорости ленты сушилки.

Предполагалось, что влажность и температура слоя зеленого чая будут поддерживаться на желаемом уровне в оптимальных условиях с помощью ОА-ОПУ. На сушилку зеленого чая подавали несколько возмущений, и наблюдали за работой системы ОПУ. Добавление приблизительного моделирования процесса сушки зеленого чая с помощью методики «планирование эксперимента» (метода оптимизации Бокса-Уилсона) к алгоритму ОПУ делает управление гораздо более эффективным при резких изменениях условий эксплуатации.

2. Моделирование процесса сушки с использованием метода Бокса-Уилсона

Конвейерная сушилка предназначена для сушки натуральных продуктов (овощей, фруктов, лекарственных трав и др.). В данной работе исследуется процесс сушки зеленого чая в такой сушилке, схематический чертеж которой показан на рис. 1. Она состоит из конвейера (1 м x 10 м), который медленно перемещает слой влажного материала через поток сушильного агента, и набора датчиков температуры, влажности. В качестве сушильного агента используется предварительно подогретый воздух с точно заданными характеристиками.

Горячий воздух поступает с постоянной скоростью 0,08-0,13 м/с и контролируется с помощью калиброванного термоанемометра (405-Б1) (Scantemp 410, TFA Dostmann, Wertheim-Reicholzheim, Германия) в каме-

ре сушилки. Сушильный агент поступает по ленточному транспортеру через зазоры снизу вверх, перпендикулярно направлению движения влажного слоя зеленого чая.




Рис. 1. Схема оцениваемой конвейерной сушилки

Потеря в массе определялась в автономном режиме путем периодического взвешивания подноса на цифровом балансе с разрешением $\pm 10^{-7}$ кг и расположенном за пределами камеры [8].

Замкнутая система управления, которая предназначена для мгновенного достижения и поддержания заданной температуры, необходимого содержания воды в слое зеленого чая в сушильной камере и на выходе в определенном диапазоне заданных значений, несмотря на возмущающие нагрузки, представлена на рис. 2.

При проектировании системы управления процессом сушки зеленого чая учитывались динамические изменения влажности корма, температуры сушки.

Для динамических и контрольных исследований использовалось компьютерное управление для контроля температуры и влажности слоя зеленого чая в сушилке. Для этого были разработаны компьютерные управляющие программы on-line.

Метод Бокса-Уилсона. В данной работе было получено математическое описание модели процесса сушки зеленого чая для системы управления сушилкой с использованием метода Бокса-Уилсона [9] (методики «Экспериментальное проектирование»). Метод Бокса-Уилсона позволяет получить математическое описание изучаемого процесса в некоторой локальной области факторного пространства, расположенной в окрестности выделенной точки с координатами. Перенесем начало координат факторного пространства в центральную точку выделенной области как пример рис. 2.




Рис. 2. Введение кодированных переменных

где u_i^0 – нормированный параметр, который записывается как [10]:

$$u_i^0 = \frac{u_i - U_{iav}}{\Delta U_i}, \quad U_{iav} = \frac{u_i^+ + u_i^-}{2}, \quad \Delta U_i = \frac{u_i^+ - u_i^-}{2},$$

где U_i – действительным параметром;

U_{iav} – среднее значение реального параметра.

Чтобы применить эту модель, выходная переменная была выражена в виде модели регрессии с условием взаимодействия.

$$y = b_0 + \sum_{i=1}^n b_i \cdot u_i. \quad (1)$$

Модель в виде матрицы:

$$Y = b_0 + B \cdot U$$

$$B = [b_1, b_2, \dots, b_n] \quad (2)$$

$$U = [u_1, u_2, \dots, u_n]^T,$$

где b_0 – значение функции отклика в начале координат, $b_0 = y(u_i^0)$;

y – выходные независимые переменные величины процесса значение (температуры выпускного слоя зеленого чая);

u_i – независимые факторы, влияющие на протекание процесса (управляющие воздействия, которые представляют собой значения температуры воздуха, скорость движение воздуха и скорость ленты);

b_i – константы статической линейной модели.

Согласно методу планирования эксперимента, чтобы найти константы линейной модели и применить оптимизацию, необходимо провести 2^n

экспериментов. Индекс « n » показывает количество независимых факторов, влияющие на протекание процесса. В настоящей работе матрица экспериментального плана приведена в табл. 1. Параметры модели линейной регрессии первого порядка определяются следующим образом:

$$b_i = \frac{\sum_{j=1}^{2^n} \varepsilon_{ij} y_j}{2^n}, \quad (3)$$

где ε_{ij} – коды значений параметров, приведенных в табл. 1.

Таблица 1

Матрица экспериментального плана

Номер опыта	X_0	X_1	X_2	X_3	...	X_n
1	+	-	-	-	⋮	-
2	+	+	-	-	⋮	-
3	+	-	+	-	⋮	-
4	+	+	+	-	⋮	-
5	+	-	-	+	⋮	-
6	+	+	-	+	⋮	-
7	+	-	+	+	⋮	-
8	+	+	+	+	⋮	-
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2^{n-1}	+	+	+	-	⋮	-
$2^{n-1}+1$	+	-	-	+	⋮	+
$2^{n-1}+2$	+	+	-	+	⋮	+
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2^n	+	+	+	+	+	+

2. Разработка УПМ с применением метода Бокса-Уилсона

Основная идея предиктивного управления состоит в том, чтобы предсказать будущее поведение системы и получить локально оптимальное решение для системы [11]. Блок-схема системы УПМ² представлена на рис. 3. Результатом решения является определение набора управляющих сигналов, соответствующих прогнозируемому значению сигнала в будущем.

В работе разработан регуляризованное прогнозирующее управление на основе применения метод Бокса-Уилсона для прогнозирования аппроксимации направления системы по величине управляющего сигнала в небольшом будущем периоде, находя оптимальный управляющий сигнал для системы в настоящее время. Проблема регулятора на основе примене-

² УПМ – Управление с прогнозирующими моделями

ния метод Бокса-Уилсона решается с помощью задачи выпукло-квадратичного программирования (КП) путем приведения целевой функции к нормальной форме. КП решается с помощью алгоритма, основанного на методе умножения Лагранжа.




Рис. 3. Блок-схема системы УПМ с применением метода Бокса-Уилсона; $y(k + 1|k)$ – выходной прогноз в моменте k ; $u(k)$ – управляющего воздействия в моменте k ; $y(r)$ – заданные значения

3.1. Регулятор

Используя метод Бокса-Уилсона для модели объекта, регулярная задача отслеживания вывода с входными ограничениями можно сформулировать следующим образом:

$$J(y, u) = \|Y_{k+1} - R_{k+1}\|_Q^2 + \|U_k - U_{k-1}\|_S^2 \quad (3)$$

$$Y_{k+1} = b_0 + B \cdot U \quad (4)$$

$$U_{max} \geq U \geq U_{min} \quad (5)$$

где Q, S – веса регуляризации; R_{k+1} – заданные значения; U – управляющего воздействия; Y_{k+1} – управляемые переменные.

Это понимается как:

$$\|Y_{k+1} - R_{k+1}\|_Q^2 = \|Y_{k+1} - R_{k+1}\|_Q \|Y_{k+1} - R_{k+1}\|^T$$

В этой статье решение представлено в виде задачи выпуклого квадратичного программирования (КП), которое построено в стандартной форме (3). Существуют различные методы оптимизации задач квадратичного программирования. В данной работе нахождение решения применяется алгоритм, основанный на методе множителей Лагранжа.

Решение задачи оптимизации квадратичного программирования

Целевая функция:

$$\begin{aligned} J(y, u) &= \|Y_{k+1} - R_{k+1}\|_Q^2 + \|U_k - U_{k-1}\|_S^2 \\ &= \|b_0 + B \cdot U - R_{k+1}\|_Q^2 + \|U - U_{k-1}\|_S^2 \end{aligned}$$

$$\begin{aligned}
&= U^T (B^T Q B + S) U \\
&+ 2(B^T Q (b_0 - R) - S U_{k-1})^T U + \\
&\quad + \|b_0 - R_{k+1}\|_Q^2 + \|U_{k-1}\|_S^2 \\
&= U^T H U + 2g^T U + p
\end{aligned}$$

где $H = B^T Q B + S$;

$$g = B^T Q (b_0 - R) - S U_{k-1};$$

$$p = \|b_0 - R_{k+1}\|_Q^2 + \|U_{k-1}\|_S^2.$$

Значит $J(y, u) \rightarrow \min$ когда $\frac{\partial J}{\partial U} = 0$

Из этого получим:

$$\begin{aligned}
2HU + 2g^T &= 0 \\
U &= -H^{-1}g^T
\end{aligned} \tag{6}$$

$$U_{max} \geq U \geq U_{min} \tag{7}$$

Затем полученный результат процесса оптимизации применяется к объекту.

3.2 Разработка автоматизированной системы управления процессом сушки зеленого чая

Целью системы автоматического управления является моделирование процесса сушки зеленого чая путем моделирования взаимосвязи между несколькими входными и выходными переменными и предоставление эффективного механизма управления УПМ с использованием метода Бокса-Уилсона для процесса сушки зеленого чая. Можно рассматривать несколько входных и выходных переменных, но для этой работы мы будем рассматривать температуру сушильного агента и скорость ленты и воздуха в камере как входные переменные, а температуру и влажность слоя зеленого чая — как выходные, так как именно эти два коэффициента оказывают наибольшее влияние на конечное качество чайного продукта.

В момент времени t определяется текущее состояние модели процесса и рассчитываются управляющие воздействия для минимизации затрат с использованием численного алгоритма минимизации в течение относительно короткого периода времени в будущем.

Алгоритм системы прогнозирующего управления, представленный на рис. 4:

Шаг 1: определить входные параметры объекта управления и ограничить область прогноза;

Шаг 2: задать начальный набор значений;

Шаг 3: построить и рассчитать константы статической линейной прогнозирующей модели объекта b_i с помощью метода Бокса-Уилсона, основанного на методике «планирование эксперимента» в процесс управления сушкой зеленого чая;

Шаг 4: определить выходное прогнозное значение системы $Y(k+1)$ в моменте k по построенной модели (шаг 3);

Шаг 5: минимизировать целевую функцию J ;

Шаг 5: определить управляющий сигнал $U(k)$;

Шаг 6: Применить управляющее воздействие к объекту и повторит шаг 1 до конца управления.

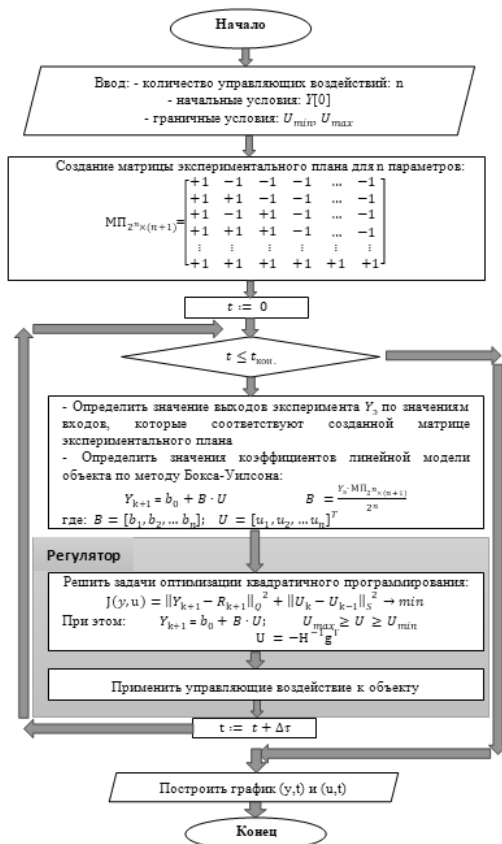


Рис. 4. Алгоритм системы прогнозирующего управления на основе применения метод Бокса-Уилсона

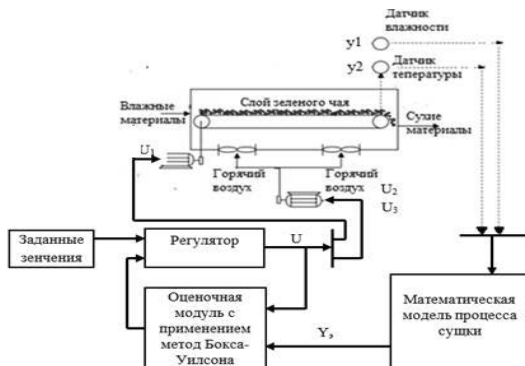


Рис. 5. Схема автоматизированная система управления технологическим процессом сушки

Таблица 2

Входные и выходные переменные

Входные	Скорость движение ленты (u_1)
	Скорость воздуха (u_2)
	Температура воздуха (u_3)
Выходные	Влажность чая (y_1)
	Температура чая (y_2)

Математическую модель для управляемых и регулируемых переменных (табл. 2) сушилки зеленого чая можно построить следующие дифференциальные уравнения в частных производных (УЧП) первого порядка, которые определяются как:

Уравнение переноса энергии [3, 4]:

$$C_p \frac{\partial T(x, \tau)}{\partial \tau} = \lambda \frac{\partial^2 T(x, \tau)}{\partial x^2}. \quad (8)$$

Начальные и граничные условия:

$$T(x, 0) = T_0 \quad (9)$$

$$\frac{\partial T(0, \tau)}{\partial x} = 0 \quad (10)$$

$$\lambda \frac{\partial T(r, \tau)}{\partial x} = k(T_c - T(r, \tau)), \quad (11)$$

где: C_p – удельная теплоемкость сухих листьев зеленого чая; $T(x, \tau)$ – температура слоя зеленого чая; r – толщина слоя; λ – коэффициент теплопроводности; T_c – температура сушильного агента, k – коэффициенты теплоотдачи; x – осевое положение вдоль конвейерной сушилки.

Уравнение переноса массы:

$$\frac{\partial M}{\partial \tau} = -u_c \frac{\partial M}{\partial x} - K(M - M_e), \quad (12)$$

где u_c – скорость конвейерной ленты, x – осевое положение вдоль конвейерной ленты-сушилки, M_e – равновесная влажность листьев чая, K – коэффициент массообмена.

$$K = 10^{-6} T_c^{2.08} u_a^{1.11}.$$

Решив такие дифференциальным уравнениям получим следующие математическую модель процесса сушки зеленого чая:

$$T = \frac{\lambda^2}{kr} \frac{2}{\sqrt{\pi}} \int_{\frac{k}{2\sqrt{t}}}^{\infty} e^{-y^2} d(y)$$

$$M = e^{-\frac{Kr}{u_c}} + K M_e e^{-Kt}.$$

Взаимодействие между температурой поверхности слоя зеленого чая и влажностью листьев чая представляет собой сложное вычислительное уравнение, поэтому для моделирования этого взаимодействия в предлагаемой работе используется построение системы нечеткой аппроксимации на основе полученных значений экспериментальных результатов и заключения экспертов.

Нечеткая аппроксимация влияния температуры поверхности слоя зеленого чая на влажность представлен на рис. 6.

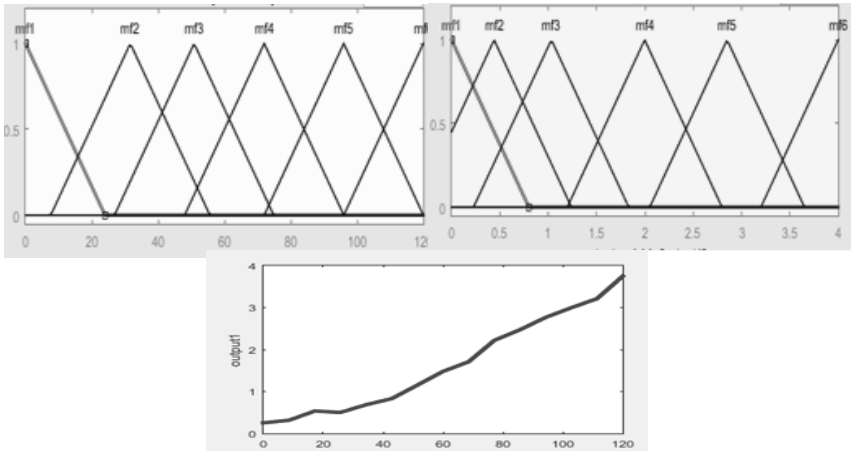


Рис. 6. Нечеткая аппроксимация влияния температуры поверхности слоя зеленого чая на влажность

Нечеткая аппроксимация влияния влажности зеленого чая на температуру поверхности слоя представлен на рис. 7.

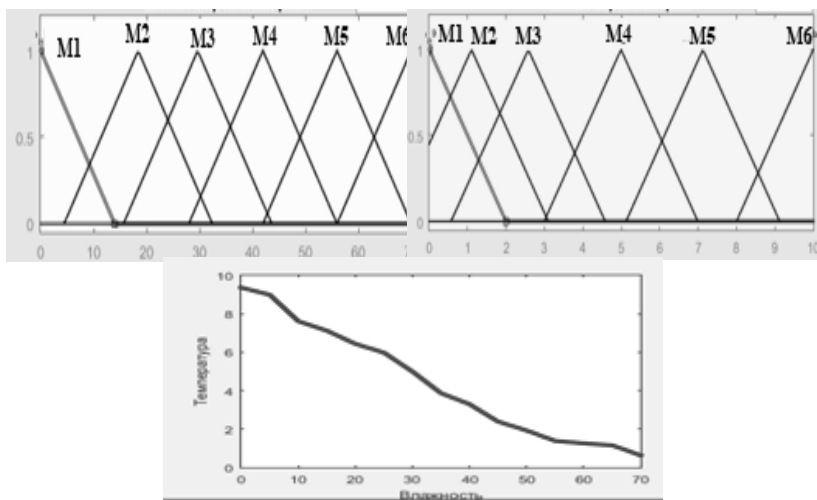


Рис. 7. Нечеткая аппроксимация влияния влажности зеленого чая на температуру поверхности слоя

Результат моделирования системы управления процессом сушки зеленого чая в рисунке 6 показало, что УПМ-регулятор стабилен и устойчив с точки зрения подавления входных возмущений и при внедрения метода Бокса-Уилсона для модели объекта в УПМ обеспечивает более эффективную работу по сравнению с традиционными УПМ (рис. 9).




Рис 9. Сравнение работы традиционными УПМ и УПМ при внедрении метода Бокса-Уилсона для моделирования процесса

Заключение

Процессы термической обработки, такие как обжарка и сушка, энергоёмки. Учитывая постоянно растущую стоимость энергии, необходимо совершенствовать технологию и систему управления процессом для снижения эксплуатационных расходов при сохранении или улучшении качества конечных чай-продуктов.

В данной работе описаны проектирование, моделирование и реализация автоматизированной системы управления АСУ процессом сушки зеленого чая в ленточной конвейерной сушилке на основе алгоритма УПМ-регулятора с применением метода Бокса-Уилсона.

Процесс сушки зеленого чая моделируется как непрерывная система, где управляющим переменным является мощность, подаваемая на электронагреватель (температура сушильного воздуха), скорости воздуха и скорости ленты, а регулируемой переменной – температура и влажность слоя зеленого чая в сушильной камере.

Результаты моделирования системы управления процессом сушки зеленого чая показывают, что УПМ-регулятор стабилен и устойчив с точки зрения подавления входных возмущений. Система управления УПМ при внедрении метода Бокса-Уилсона для модели объекта обеспечивает более эффективную работу по сравнению с традиционными УПМ.

Список литературы

- [Хасанова 2016] Хасанова С.Р. Экспериментально-теоретическое обоснование создания и стандартизации лекарственных растительных препаратов с антиоксидантной активностью: дисс. ... док-ра. фарм. наук: 15.00.02 – М, 2016.
- [Лакиза и др., 2016] Анализ пищевых продуктов: учеб. пособие. М-во образования и науки Рос. Федерации, Урал. федер. ун-т. – Екатеринбург: Изд-во Урал. ун-та, 2015.
- [Никерова, 2020] Никерова К.М. Активность ферментов антиоксидантной системы при изменении сценариев ксилогенеза: дисс. ... док-ра. био. наук: 03.01.05. – Петрозаводск, 2020.
- [Александров, 2011] Александров А.Г. Самонастраивающийся ПИД/И-регулятор // Учреждение Российской Академии Наук Институт Проблем Управления им. В.А. Трапезникова РАН, 2011.
- [Pamuk и др., 1990] V. Pamuk, M. Alpbaz, S.R. Asgharpour, The dynamics of packed distillation column distilling the mixture of water-methyl-alcohol under the effect of several disturbances // J. Chemistry. – 1990. – 14
- [Белов и др., 2019] Белов М.П., Фьюнг Ч.Х. Адаптивное прогнозирующее управление следящими электроприводами нелинейных систем с упругими связями // Известия СПбГЭТУ «ЛЭТИ». – 2019. – № 3.

- [Фам и др., 2022] Фам К.Б., Богатиков В.Н. Исследование динамических свойств системы управления с нечеткими регуляторами процесса сушки зеленого чая // XI Международной научно-практической конференции «Интегрированные модели и мягкие вычисления в искусственном интеллекте». – 2022.
- [Комиссаров и др., 2011] Комиссаров Ю.А., Гордеев Л.С., Вент Д.П. Процессы и аппараты химической технологии. – М.: Химия, 2011.
- [Попов, 2015] Попов А.А. Математические методы планирования эксперимента: методические указания к лабораторным работам для студентов IV-го курса ФПМИ // Новосиб. гос. техн. ун-т. – Новосибирск.
- [Ланин, 2015] Ланин В.Л. Математическое моделирование и оптимизация технологических процессов изготовления приборов электронной техники // пособие – Минск: БГУИРб 2015. – 66 с.
- [Жучков] Жучков Р.Н. Применение идей прогнозирующего управления в синтезе стабилизирующего управления сетевыми объектами. Арзамасский политехнический институт (филиал) Нижегородского государственного технического университета им. Р.Е. Алексеева, Арзамас.

УДК 004.822

ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ НА ОСНОВЕ НЕБИНАРНЫХ НЕЙРОНОВ С ВРЕМЕННОЙ СУММАЦИЕЙ СИГНАЛОВ В ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ

А.А. Харламов (*kharlamov@analyst.ru*)

Институт высшей нервной деятельности
и нейрофизиологии РАН, Москва,
МГЛУ, Москва, ВШЭ, Москва, МФТИ, Долгопрудный

Н.С. Бородин (*nsborodin@edu.hse.ru*)

Высшая школа экономики, Москва

В работе описываются искусственные нейронные сети на основе нейронов с временной суммацией сигналов. Показано расширение класса сетей на небинарный случай анализируемых входных последовательностей. Качество работы таких сетей, обученных на кодовых последовательностях звучащей речи, показано на задаче синтеза речевой волны.

Ключевые слова: искусственные нейронные сети на основе нейронов с временной суммацией сигналов, нейрон с небинарным входом, речевой сигнал, обучение, синтез.

Введение

Искусственные нейронные сети на основе нейроподобных элементов с временной суммацией сигналов реализуют структурную обработку информации и потому могут быть использованы в интеллектуальных системах.

Описан случай реализации структурной обработки информации с помощью искусственных нейронных сетей на основе нейронов с временной суммацией сигналов с бинарным входом [Харламов 2017]. Это описание скорее философского характера: математические выкладки показывают подробности структурного анализа, но не могут быть реализованы при анализе реальной информации. Расширение этого представления на небинарный случай позволяет алгоритмизировать представление. Реализованная в результате модель небинарного нейрона позволяет успешно работать с реальной информацией.

В реальных ситуациях обработки информации входные кодовые последовательности как правило представляется небинарно. В работе показано расширение формального описания искусственных нейронных сетей на основе нейронов с временной суммацией сигналов на случай с небинарным входом.

Колонка коры (точнее, множество пирамидных нейронов третьего слоя коры, осуществляющих структурную обработку специфической информации – см. рис. 2, 3) моделирует адресами своих нейронов точки многомерного сигнального пространства, в которое отображаются сформированные на сигнальном уровне кодовые последовательности [Харламов 2017, Neuroinformatics and Semantic Representations 2020] и где осуществляется их последующая структурная обработка. В бинарном случае отображение осуществляется в n -мерный единичный гиперкуб G_e^n ($G_e^n \in R^n$, где R^n – многомерное пространство).




Рис. 1. Бинарный нейрон с временной суммацией входных сигналов.

1. Вход. 2. Возбуждающие синапсы.
3. Тормозные синапсы. 4. Тело клетки (сумматор).
5. Выход.
6. Обобщенный дендрит – многозарядный регистр сдвига.
7. Управляющий синапс




Рис. 2. Колонка нейронов, осуществляющая структурную обработку информации. Здесь 1 – включенные параллельно нейроподобные элементы с временной суммацией сигналов, 2 – их общий информационный вход 3 – управляющий вход

Определение 1. Бинарный нейрон отображает фрагмент входной двоичной кодовой последовательности длины n символов в вершину n -мерного единичного гиперкуба $\hat{a}_i \in G_e^n$.

Обозначим через $\{A\}$ множество кодовых последовательностей, сформированных сигнальной периферией анализаторов, элементы которых есть символы, из которых состоят коды входных последовательностей $A = (... a_{-1}, a_0, a_1, ..., a_i, ...)$. В бинарном случае $a_i \in \{0, 1\}$. Обозначим

через $\{\hat{A}\}$ – множество траекторий последовательностей, соответствующих множеству входных последовательностей $\{A\}$, элементы которых есть точки пространства R^n , т.е. вершины единичного гиперкуба $\hat{a}_i \in G_e^n$, где $\hat{a}_i = (a_{i-n+1}, a_{i-n+2}, \dots, a_i)$ – последовательные фрагменты последовательности A длины n символов, сдвинутые относительно друг друга на один символ (на один такт времени). Тогда возможно ассоциативное преобразование F_n , формирующее траекторию в n -мерном сигнальном пространстве:

$$F_n: A \rightarrow \hat{A}, F_n(A) = \hat{A}. \quad (1)$$

Ассоциативность преобразования (1) позволяет сохранить топологию структуры преобразуемой информации: одинаковые фрагменты входной последовательности преобразуются в один и тот же фрагмент траектории.

Пусть задана некоторая последовательность J и траектория $\hat{A} \in R^n$, соответствующая последовательности A . Введем функцию M (2), ставящую в соответствие каждой точке траектории \hat{A} элемент последовательности J :

$$M(\hat{a}_i, j_{i+1}) = [\hat{a}_i]_{j_{i+1}}. \quad (2)$$

Полученную траекторию $[\hat{A}]_j$ будем называть траекторией, обусловленной последовательностью J :

$$[\hat{A}]_j = M(F_n(A), J). \quad (3)$$

Восстановление информационной последовательности J по обусловленной ею траектории $[\hat{A}]_j$ и несущей последовательности A осуществляется с помощью функции:

$$R([\hat{A}]_j) = J, \quad (4)$$

где R назовем функцией считывания.

Пусть механизм памяти (2) представляет собой счетчик, фиксирующий число прохождений заданной точки траектории в заданном направлении. Механизм памяти, чувствительный к числу прохождений заданной вершины в заданном направлении, является инструментом для анализа входной последовательности с точки зрения повторяющихся ее частей, поскольку одинаковые фрагменты последовательности отображаются преобразованием F_n в одну и ту же часть траектории.

Введем пороговое преобразование H с порогом h . Тогда суперпозиция функций $H_h R M F_n(A)$ позволит выделить в сигнальном пространстве только такие точки траектории, которые были пройдены не менее h раз. Они формируют словарь $\{\hat{B}\}$.

$$\{\hat{B}\} = H_n R M F_n(\{A\}). \quad (5)$$

Сформированный словарь может быть использован для детектирования старой информации в потоке новой. Для этого необходимо поглощение фрагментов входной последовательности \hat{A} , соответствующих словам словаря, и пропускание новой, относительно словаря информации. Так формируется так называемая синтаксическая последовательность C :

$$F_{n,C}^{-1}(\hat{A}, \{\hat{B}_j\}) = C, \quad (6)$$

которую далее можно использовать для формирования словаря $\{\hat{D}\}$ следующего уровня.

Судя по терминологии, можно было бы попытаться увидеть здесь некоторую аналогию с импульсными нейронными сетями [Szatmary and Izhikevich 2010]. На самом деле никакого сходства даже близко здесь нет: в импульсных нейронных сетях учитывается задержка сигнала при передаче его по аксону. Не вполне понятно, где в естественном нейроне хранится информация об этой задержке. В данной статье речь идет об электронеконтактных нейронах, где задержка реализуется при прохождении постсинаптическим потенциалом по мембране дендрита, и эта задержка и учитывается в случае временной суммации сигналов. В результате в памяти нейрона учитывается не только пространственный рисунок поступивших на его синапсы сигналов, но и временная картина динамики этих сигналов.

1. Искусственная нейронная сеть на основе нейроподобных элементов с временной суммацией сигналов. Небинарный случай

Определение 2. Небинарный нейрон отображает фрагмент входной кодовой последовательности векторов длины n размерности k с действительными значениями в вершину $(n \times k)$ -мерного пространства $\hat{a}_i \in R^{n \times k}$.

В небинарном случае пирамидные нейроны третьего слоя колонки коры моделируются так называемым динамическим ассоциативным запоминающим устройством (далее – ДАЗУ), которое представляет собой множество параллельно включенных нейроподобных элементов, запоминающих в соответствующих счетчиках совместные появления фрагментов длины n входной кодовой последовательности, состоящей из k -разрядных векторов и сопутствующей информации.

Нейроподобный элемент состоит из k регистров сдвига (обобщенных дендритов длины n), сумматора, порогового преобразователя, а также области памяти, включающей счетчики учета частоты совместного появления (см. рис. 3).




Рис. 3. Нейроподобный элемент с временной суммацией сигналов, у которого имеется несколько (k) обобщенных дендритов (в данном случае – регистров сдвига одной длины n), включающий сумматор и пороговый преобразователь

Помимо дендритов, сумматора и порогового устройства в состав нейрона входит область памяти для записи гетероассоциативной информации и счетчики, которые считают число совместных появлений адреса нейрона во входной кодовой последовательности и сопутствующей адресу информации. В качестве входной кодовой последовательности используется последовательность k -значных векторов признаков, элементами которых являются неотрицательные действительные числа. (Взято из [Радченко 1969]).

1.1. Структурная обработка в колонках коры. Небинарный случай

В отличие от бинарного случая обозначим через $\{A\}$ множество кодовых последовательностей, сформированных сигнальной периферией некоторого (например, речевого) анализатора, элементы которых есть векторы признаков, из которых состоят входные кодовые последовательности $A = (\dots a_{-1}, a_0, a_1, \dots, a_i, \dots)$, где a_i – k -значный вектор признаков, компоненты которого – неотрицательные действительные числа (например кепстральные коэффициенты).

Тогда $\{\hat{A}\}$ – множество траекторий последовательностей, соответствующих множеству входных последовательностей $\{A\}$, элементы которых \hat{a}_i есть точки пространства $R^{n \times k}$, т.е. $\hat{a}_i \in R^{n \times k}$, где $\hat{a}_i = (a_{i-n \times k + 1}, a_{i-n \times k + 2}, \dots, a_i)$ – последовательные фрагменты последовательности A длины n k -значных векторов, сдвинутые относительно друг друга на один вектор (на один такт времени) – координаты точек многомерного пространства $R^{n \times k}$.

Тогда ассоциативное преобразование $F_{n \times k}$ имеет вид:

$$F_{n \times k}: A \rightarrow \hat{A}, F_{n \times k}(A) = \hat{A}, \quad (7)$$

где $\mathbf{A} = (\dots, \mathbf{a}_i, \dots: \mathbf{a}_i \in R^{n \times k})$,
а $\hat{\mathbf{A}} = (\dots, \hat{\mathbf{a}}_{-2}, \hat{\mathbf{a}}_{-1}, \dots, \hat{\mathbf{a}}_i, \dots) =$
 $= ((\mathbf{a}_{-n \times k - 1}, \mathbf{a}_{-n \times k}, \dots, \mathbf{a}_{-2}), (\mathbf{a}_{-n \times k}, \mathbf{a}_{-n \times k + 1}, \dots, \mathbf{a}_{-1}),$
 $\dots, (\mathbf{a}_{-n \times k}, \mathbf{a}_{-n \times k + 1}, \dots, \mathbf{a}_{-1}) \dots)$.

Введенное преобразование $F_{n \times k}$, которое формирует траекторию в $n \times k$ -мерном сигнальном пространстве, и координаты точек которой задаются n -членными фрагментами исходной входной векторной последовательности \mathbf{A} , является основой для структурной обработки информации (также, как и в бинарном случае).

Также, как и в бинарном случае, траекторию $[\hat{\mathbf{A}}]_j$ будем называть траекторией, обусловленной последовательностью J :

$$[\hat{\mathbf{A}}]_j = M(F_{n \times k}(\mathbf{A}), J). \quad (8)$$

Также, как и в бинарном случае, формируются словари и синтаксические последовательности, только в отличие от бинарного случая их траектории располагаются во всем $(n \times k)$ -мерном пространстве $R^{n \times k}$.

1.2. Расфокусированное преобразование

Расширением понятия преобразования F является расфокусированное преобразование $F_{(r)}$ [Харламов, 2017; Neuroinformatics and Semantic Representations, 2020], преобразующее каждый n -членный фрагмент векторов последовательности не в точку многомерного пространства, а в множество вершин, лежащих в окрестности указанной вершины радиуса r . Исходная последовательность \mathbf{A} , таким образом, отображается в трубку радиуса r с осью-траекторией $\hat{\mathbf{A}}$:

$$\hat{\mathbf{A}}_{(r)} = F_{(r)}(\mathbf{A}). \quad (9)$$

Использование расфокусированного преобразования $F_{(r)}$ позволяет увеличить надежность воспроизведения, если при обучении была сформирована нерасфокусированная траектория. При этом, в случае ухода с траектории, в результате зашумления входной информации (например, замены части символов на противоположные), среди точек r -той окрестности текущей точки траектории могут содержаться и точки траектории, в которых записана нужная информация. При воспроизведении на основе этой информации (информации о переходе, содержащейся в счетчиках точек r -ой окрестности), а также взятой со своим весом информации о следующем символе входной последовательности, инициировавшей воспроизведение, принимается решение о следующем символе воспроизводимой последовательности. Решение принимается на основе сравнения значений счетчиков для всех точек r -ой окрестности.

В этом случае воспроизведение осуществляется по формуле:

$$\mathbf{a}_{i+1} = R([\hat{a}_i]) = R(C_{\hat{a}_i}(t)) \mid \mathbf{a}_{i+1} \in V_{r, \mathbf{a}_i}^{n \times k}, \quad (10)$$

где $V_{r, \mathbf{a}_i}^{n \times k}$ – окрестность радиуса r точки $\mathbf{a}_i \in R^{n \times k}$.

2. Модель кортикоморфной памяти в обработке речевого сигнала

Модель представляет многомерное векторное пространство, в которое отображается входная кодовая последовательность. В качестве траектории рассматривается последовательность из гиперсфер с заданными радиусами.

В процессе обучения модели по входной последовательности векторов признаков с единичным сдвигом перемещается окно заданной ширины, совпадающей с количеством вершин в траектории одного нейрона. Производится гетероассоциативная запись последовательности интерпретаций фрагментов кодовой последовательности по синхронизированной во времени последовательности фрагментов траекторий в векторном пространстве.

Речевая волна анализировалась с вычислением векторов коэффициентов кепстра в шкале мелов для временного окна длиной в 0.01 с. Число частотных ячеек быстрого преобразования Фурье было выбрано экспериментальным путём и составило 2048 единиц. Итоговая размерность векторов признаков с целью сохранения наиболее полной информации для дальнейшего синтеза численно совпадала с количеством мел-фильтров и равнялась 128.

Для обучения ДАЗУ использовалась обучающая выборка из 380 предложений англоязычной базы TIMIT (TRAIN\DR1). Всего 14 женских и 14 мужских голосов.

При распознавании использовались предложения из соответствующей тестовой директории (TEST\DR1). Ни один из тестовых голосов не присутствовал в обучающей выборке.

Синтез речи осуществлялся синтезатором речи [Petgaudin 2013] на основе векторов признаков, полученных при распознавании последовательности звукотипов произнесенных слов. Количество итераций алгоритма Гриффина-Лима было подобрано из соотношения времени и качества реконструкции и составило 300 единиц.

Оценка качества осуществлялась сравнением по взвешенному коэффициенту детерминации векторов признаков входной и синтезированной звуковых последовательностей. Данная метрика позволяет масштабировать показатель качества регрессии на диапазон $[0; 1]$ (значения ниже нуля означают прогноз, уступающий наивному, а потому неприемлемый).

Заключение

В работе показано, что структурная обработка, которая осуществляется в колонках коры и результатом которой является формирование словаря часто повторяющихся событий, может быть использована для анализа кодовых сенсорных последовательностей (например, речевой волны). Сформированный словарь повторяющихся элементов (звуков речи) является в этом случае основой для восстановления запомненной при обучении информации. Так качество синтезированной речи, полученное с помощью обученной модели колонки коры, оказывается очень высоким. Единственная особенность результата заключается в том, что модель, обученная на дикторов мужчин и дикторов женщин, при синтезе формирует речевую волну, включающую в свой состав иногда звучащую речь как речь мужчины, иногда как речь – женщины. Звучит это, конечно, очень своеобразно.

Список литературы

- [Кудашев 2014] Кудашев О.Ю. Система разделения дикторов на основе вероятностного линейного дискриминантного анализа: дис. ... канд. техн. наук: 05.13.11. – СПб.: ИТМО. 2014.
- [Радченко 1969] Радченко А.Н. Моделирование основных механизмов мозга. – Л.: Наука, 1969.
- [Харламов 2017] Харламов А.А. Ассоциативная память – среда для формирования пространства знаний. От биологии к приложениям. – Дюссельдорф: Palmarium Academic Publishing, 2017.
- [Perraudin 2013] Perraudin Nathanaël, Balazs Peter, Søndergaard Peter L. A fast Griffin-Lim algorithm // IEEE Workshop on Applications of Signal Processing to Audio and Acoustics – New Paltz, NY:, 2013.
- [Neuroinformatics and Semantic Representations 2020] Neuroinformatics and Semantic Representations. Theory and Applications / Alexander Kharlamov & Maria Pilgun eds. Cambridge Scholars Publishing: 2020.
- [Szatmary and Izhikevich 2010] Szatmary B. and Izhikevich E.M. Spike-Timing Theory of Working Memory. PLoS Computational Biology. – 2010. – Vol. 6, Issue 8.

УДК 517.977.5

ДИНАМИЧЕСКАЯ МОДЕЛЬ ОПТИМАЛЬНОГО УПРАВЛЕНИЯ ОБУЧЕНИЕМ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Е.Г. Царькова (*univesrity69@mail.ru*)

Тверской государственнй университет, Тверь

В работе осуществлено моделирование искусственной нейронной сети (ИНС), разработан алгоритм обучения нейросетевой модели, описываемой системой дифференциальных уравнений. Для решения задачи обучения ИНС применен аппарат оптимального управления. С учетом заданных ограничений и вида целевого функционала сформулированы необходимые условия оптимальности для весовых коэффициентов сети и внешнего управляющего воздействия, построена соответствующая дискретная задача оптимального управления, для решения которой может быть применен метод быстрого автоматического дифференцирования.

Ключевые слова: искусственная нейронная сеть, обучение нейронной сети, принцип максимума Понтрягина, метод быстрого автоматического дифференцирования, метод проекции градиента.

Введение

Сегодня в различных системах управления активно применяются искусственные нейронные сети (ИНС). Для решения ряда прикладных задач могут быть применены стандартные методы обучения ИНС, однако при управлении большими системами появляется необходимость в моделировании нейронных сетей достаточно сложной, нетривиальной структуры. Для обучения произвольной искусственной нейронной сети может быть применен аппарат оптимального управления, с использованием которого осуществляется поиск оптимальных значений весовых коэффициентов ИНС, минимизирующих ошибку обучения, энергию сети и(или) время обучения. Широкий спектр методов решения получаемых задач оптимального управления и хорошие аппроксимирующие свойства нейронных сетей позволяют эффективно использовать обученные нейронные сети для моделирования динамических управляемых процессов.

1. Постановка задачи

В общем случае состояние нейронной сети из N нейронов, описывается нелинейной системой дифференциальных уравнений второго порядка с запаздыванием [Андреева, 2015]:

$$\begin{aligned} \ddot{x}_i(t) + \varepsilon(1 - \beta_i x_i^2(t)) + v_i^2 x_i(t) = \\ = u_i(t) + \sum_{j=1}^N w_{ij}(t) \left(\dot{x}_j(t - h_j) - \dot{x}_i(t) \right), \end{aligned} \quad (1.1)$$

где $i = \overline{1, N}, t \in [0, T]$.

Введем следующие обозначения:

$$\begin{aligned} \dot{x}_i(t) &= y_i(t), \\ z_j(t) &= y_j(t - h_j), j = \overline{1, N}, t \in [0, T], \end{aligned}$$

и перепишем уравнение (1) в виде системы дифференциальных уравнений первого порядка:

$$\dot{x}_i(t) = y_i(t), \quad j = \overline{1, N}, t \in [0, T], \quad (1.2)$$

$$\begin{aligned} \dot{y}_i(t) = -v_i^2 x_i(t) - \varepsilon(1 - \beta_i x_i^2(t)) + \\ + u_i(t) + \sum_{j=1}^N w_{ij}(t) \left(y_j(t - h_j) - y_i(t) \right). \end{aligned} \quad (1.3)$$

Учитываем начальные условия:

$$x_i(0) = a_i, \quad (1.4)$$

$$\dot{x}_i(t) = \varphi_i(t), \quad i = \overline{1, N}, t \in [-\max\{h_j\}, 0], \quad (1.5)$$

и ограничениями на управляющие воздействия:

$$|u_i(t)| < B_i, |w_{ij}(t)| < C_{ij}. \quad (1.6)$$

Здесь x_i – амплитуда колебаний i -го нейрона; $y_i(t)$ – скорость изменения амплитуды колебаний i -го нейрона; $u(t)$ – функция управления, характеризующая внешнее воздействие ансамбля нейронов на i -й нейрон; N – количество нейронов; T – фиксированное время протекания процесса; $\varepsilon > 0$ и β – коэффициенты, характеризующие нелинейное воздействие на i -ый нейрон ансамбля нейронов (в частности, β влияет на силу зату-

хания колебания i -го нейрона), ν_i – собственная частота колебания i -го нейрона. Особенностью данной математической модели является учет запаздывания при передаче сигнала от одного нейрона к другому.

Целью управления искусственной нейронной сетью является ее обучение, которое включает в себя следующие этапы:

- построение процесса, при котором в конечный момент времени характеристики нейронов будут совпадать с заданными терминальными условиями;
- построение оптимального управления $\bar{u}(t)$ ансамблем нейронов с целью минимизации значения целевого функционала.

Задача оптимального управления обучения искусственной нейронной сети сводится к минимизации функционала:

$$I(u) = M_1 \int_0^T f_0(t, x(t), u(t), w(t)) dt + M_2 \Phi(x(T)) \rightarrow \inf, \quad (1.7)$$

при ограничениях (1.2)–(1.6). Здесь M_1, M_2 – весовые коэффициенты в двухкритериальной задаче оптимального управления.

2. Необходимые условия оптимальности

Для определения функции управления в задаче (1.2)–(1.6) воспользуемся принципом максимума для динамических систем с запаздывающим аргументом, описанным в [Андреева, 2015], [Лебедев, 2019], [Андреева, 2006].

Функция Понтрягина задачи (2) – (6) имеет вид:

$$H(\lambda_0, x, y, z, p(t), q(t), u, w) = -\lambda_0 M_1 f_0(t, x, u, w) + \sum_{i=1}^N p_i(t) y_i + \sum_{i=1}^N q_i(t) \left(-(v_i)^2 x_i - \varepsilon (1 - \beta_i x_i^2) + u_i + \sum_{j=1}^N w_{ij} (z_j - y_i) \right), \quad (2.1)$$

где $z_j = y_j(t - h_j)$, $j = \overline{1, N}$, $t \in [0, T]$; $p(t), q(t)$ – сопряженные вектор-функции.

Для получения сопряженной системы используем принцип максимума для задачи с запаздывающим аргументом [Андреева, 2015]. Согласно этому принципу сопряженные вектор-функции $p(t), q(t)$ удовлетворяют системе дифференциальных уравнений:

$$\dot{p}_k(t) = -\frac{\partial H}{\partial x_k}(\lambda_0, \bar{x}(t), \bar{y}(t), \bar{z}(t), p(t), q(t), \bar{u}(t), \bar{w}(t)), \quad (2.2)$$

$$\begin{aligned} \dot{q}_k(t) = & -\frac{\partial H}{\partial y_k}(\lambda_0, \bar{x}(t), \bar{y}(t), \bar{z}(t), p(t), q(t), \bar{u}(t)) - \\ & -\frac{\partial H}{\partial z_k}(\lambda_0, \bar{x}(t+h_k), \bar{y}(t+h_k), \bar{z}(t+h_k), \\ & p(t+h_k), q(t+h_k), \bar{u}(t+h_k), \bar{w}(t+h_k)). \end{aligned} \quad (2.3)$$

С учетом определения функции Понтрягина (2.1) система (2.2)-(2.3) запишется в виде:

$$\dot{p}_k(t) = \lambda_0 M_1 \frac{\partial f_0(t, \bar{x}(t), \bar{u}(t), \bar{w}(t))}{\partial x_k} + q_k(t)(v_k)^2 - 2q_k(t)\varepsilon\beta\bar{x}_k(t), \quad (2.4)$$

$$\dot{q}_k(t) = -p_k(t) + q_k(t) \sum_{i=1}^N \bar{w}_{ik}(t) - \sum_{i=1}^N q_i(t+h_i) \bar{w}_{ik}(t+h_i), \quad (2.5)$$

Для сопряженной системы (2.4)–(2.5) выполняются условия трансверсальности:

$$p_k(T) = -\lambda_0 M_2 \frac{\partial \Phi}{\partial x_k}(\bar{x}(T)),$$

$$q_k(T) = -\lambda_0 M_2 \frac{\partial \Phi}{\partial y_k}(\bar{x}(T)),$$

$$q_k(t) = 0, t > T, k = 1, \dots, N.$$

Принцип максимума позволяет свести задачу построения оптимального процесса к решению краевой задачи [Андреева, 2006], которая включает в себя дифференциальные уравнения с отклоняющимся аргументом и граничные условия:

$$\dot{x}_i(t) = y_i(t), \quad j = \overline{1, N}, t \in [0, T],$$

$$\dot{y}_i(t) = -v_i^2 x_i(t) - \varepsilon(1 - \beta_i x_i^2(t)) +$$

$$+ u_i(t) + \sum_{j=1}^N w_{ij}(t) \left(\dot{y}_j(t-h_j) - \dot{y}_i(t) \right),$$

$$x_i(0) = a_i, \quad \dot{x}_i(t) = \varphi_i(t), \quad i = \overline{1, N}, t \in [-\max\{h_j\}, 0],$$

$$\begin{aligned}
\dot{p}_k(t) &= \lambda_0 R_1 \frac{\partial f_0(t, \bar{x}(t), \bar{u}(t), \bar{w}(t))}{\partial x_k} + q_k(t)(v_k)^2 - 2q_k(t)\varepsilon\beta\bar{x}_k(t), \\
\dot{q}_k(t) &= -p_k(t) + \sum_{i=1}^N q_i(t)w_{ik}(t) - \sum_{i=1}^N q_i(t+h_i)w_{ki}(t+h_k), \\
p_k(T) &= -\lambda_0 M_2 \frac{\partial \Phi}{\partial x_k}(\bar{x}(T)), \\
q_k(T) &= -\lambda_0 M_2 \frac{\partial \Phi}{\partial y_k}(\bar{x}(T)), \quad q_k(t) = 0, t > T, k = 1, \dots, N.
\end{aligned}$$

Рассмотрим частный случай при:

$$f_0(t, x(t), u(t), \omega(t)) = R_1 \sum_{i,j=1}^N u_i^2(t) + R_2 \sum_{i,j=1}^N \omega_{ij}^2(t) \text{ и } \Phi(x(T)) = \sum_{i=1}^N (x_i(T) - A_i)^2.$$

Тогда минимизируемый функционал примет вид:

$$I(u) = M_1 \int_0^T \left(R_1 \sum_{i,j=1}^N u_i^2(t) + R_2 \sum_{i,j=1}^N w_{ij}^2(t) \right) dt + M_2 \sum_{i=1}^N (x_i(T) - A_i)^2 \rightarrow \inf$$

Функция Понтрягина запишется в виде:

$$\begin{aligned}
H(\lambda_0, x, y, z, p(t), q(t), u, w) &= -\lambda_0 M_1 \left(R_1 \sum_{i,j=1}^N u_i^2(t) + R_2 \sum_{i,j=1}^N w_{ij}^2(t) \right) + \\
&+ \sum_{i=1}^N p_i(t)y_i + \sum_{i=1}^N q_i(t) \left(-v_i^2 x_i - \varepsilon(1 - \beta_i x_i^2) + u_i + \sum_{j=1}^N w_{ij} \left(z_j - y_i \right) \right).
\end{aligned}$$

Условие максимума примет вид:

$$\begin{aligned}
&-\lambda_0 M_1 \left(R_1 \sum_{i,j=1}^N u_i^2(t) + R_2 \sum_{i,j=1}^N w_{ij}^2(t) \right) + \sum_{i=1}^N p_i(t)y_i + \\
&+ \sum_{i=1}^N q_i(t) \left(-v_i^2 x_i - \varepsilon(1 - \beta_i x_i^2) + u_i + \sum_{j=1}^N w_{ij} \left(z_j - y_i \right) \right) = \\
&= \sum_{i=1}^N p_i(t)\bar{y}_i + \sum_{i=1}^N q_i(t) \left(-v_i^2 \bar{x}_i - \varepsilon(1 - \beta_i \bar{x}_i^2) \right) + \\
&+ \max_{u \in U} \left[-\lambda_0 M_1 R_1 \sum_i u_i^2(t) + \sum_{i,j=1}^N q_i(t)u_i \right] +
\end{aligned} \tag{2.6}$$

$$+ \max_{w \in W} \left[-\lambda_0 M_1 R_2 \sum_i^N w_{ij}^2(t) + \sum_{i=1}^N \sum_{j=1}^N \left(q_i(t) w_{ij} (\bar{z}_j - \bar{y}_i) \right) \right]$$

Из (2.6) получаем:

$$\bar{u}_i(t) = \begin{cases} \frac{q_i(t)}{2\lambda_0 M_1 R_1}, & \text{если } \left| \frac{q_i(t)}{2\lambda_0 M_1 R_1} \right| \leq B_i, \\ B_i, & \text{если } \frac{q_i(t)}{2\lambda_0 M_1 R_1} > B_i, \\ -B_i, & \text{если } \frac{q_i(t)}{2\lambda_0 M_1 R_1} < -B_i, \end{cases} \quad (2.7)$$

$$\bar{w}_{ij}(t) = \begin{cases} \frac{q_i(t)(\bar{z}_j - \bar{y}_i)}{2\lambda_0 M_1 R_2}, & \text{если } \left| \frac{q_i(t)(\bar{z}_j - \bar{y}_i)}{2\lambda_0 M_1 R_2} \right| \leq C_i, \\ C_i, & \text{если } \frac{q_i(t)(\bar{z}_j - \bar{y}_i)}{2\lambda_0 M_1 R_2} > C_i, \\ -C_i, & \text{если } \frac{q_i(t)(\bar{z}_j - \bar{y}_i)}{2\lambda_0 M_1 R_2} < -C_i. \end{cases} \quad (2.8)$$

Сопряженная система и условия трансверсальности примут вид:

$$\begin{aligned} \dot{p}_k(t) &= q_k(t)(v_k)^2 - 2q_k(t)\varepsilon\beta\bar{x}_k(t), \\ \dot{q}_k(t) &= -p_k(t) + \sum_{i=1}^N q_i(t)w_{ik}(t) - \sum_{i=1}^N q_i(t+h_i)w_{ik}(t+h_k), \\ p_k(T) &= -2\lambda_0(x_k(t) - A_k)M_3, \\ q_k(T) &= -2\lambda_0(x_k(t) - A_k)M_3, \quad q_k(t) = 0, t > T, k = 1, \dots, N. \end{aligned}$$

Красная задача принципа максимума имеет вид:

$$\begin{aligned} \dot{x}_i(t) &= y_i(t), \\ \dot{y}_i(t) &= -v_i^2 x_i(t) - \varepsilon(1 - \beta_i x_i^2(t)) + \\ &+ \bar{u}_i(t) + \sum_{j=1}^N \bar{w}_{ij}(t) \left(\dot{y}_j(t-h_j) - \dot{y}_i(t) \right), \\ x_i(0) &= a_i, \quad \dot{x}_i(t) = \varphi_i(t), \quad i = \overline{1, N}, t \in [-\max\{h_j\}, 0], \end{aligned}$$

$$\begin{aligned}
\dot{p}_k(t) &= q_k(t)v_k^2 - 2q_k(t)\varepsilon\beta x_k(t), \\
\dot{q}_k(t) &= -p_k(t) + \sum_{i=1}^N q_i(t)\bar{w}_{ik}(t) - \sum_{i=1}^N q_i(t+h_i)\bar{w}_{ik}(t+h_k), \\
p_k(T) &= -2\lambda_0(x_k(t) - A_k)M_3, \\
q_k(t) &= 0, t \geq T; i, k = \overline{1, N}.
\end{aligned}$$

где управления $\bar{u}_i(t)$ определяются по формуле (2.7), а $\bar{w}_{ij}(t)$ – по формуле (2.8).

Разбивая временной интервал $[0, T]$ на q слоев и аппроксимируя интеграл по правилу левых прямоугольников, а систему дифференциальных уравнений по схеме Эйлера, получим дискретную задачу оптимального управления [Андреева, 2006]:

$$I(u, w) = M_1 \sum_{i,j=1}^N f_0(t, x^l, u^l, w^l) \Delta t + M_2 \Phi(x^N) \rightarrow \inf, \quad (2.9)$$

$$x_i^{l+1} = x_i^l + \Delta t y_i^l, \quad (2.10)$$

$$y_i^{l+1} = y_i^l + \Delta t \left(-(v_i^l)^2 x_i^l - \varepsilon \left(1 - \beta_i(x_i^l)^2 \right) + u_i^l + \sum_{j=1}^N w_{ij}^l (y_j^{l-\tau_j} - y_i^l) \right), \quad (2.11)$$

$$x_i^0 = a_i, y_i^l = \varphi_i^l, l \in [-\max\{v_j\}, 0], \quad (2.12)$$

$$|u_i^l| < B_i. \quad (2.13)$$

Здесь и далее нижний индекс $i = \overline{1, N}$ – номер координаты вектора, а верхний $l = \overline{1, q}$ – номер нейронного слоя в схеме аппроксимации. Для построения решения дискретной задачи оптимального управления может быть применен метод быстрого автоматического дифференцирования (БАД), изложенный в работе [Евтушенко, 1982]. Для дискретной задачи оптимального управления (2.9)-(2.13) построим функцию Лагранжа:

$$\begin{aligned}
L(x, u, w, p, q, \lambda_0) &= \lambda_0 \left(M_1 \sum_{l=0}^{q-1} f_0(t, x^l, u^l, w^l) \Delta t \right) + \lambda_0 M_2 \sum_{i=1}^N \Phi(x^q) + \\
&+ \sum_{l=0}^{q-1} \sum_{i=1}^N p_i^{l+1} (x_i^{l+1} - x_i^l - \Delta t y_i^l) + \sum_{l=0}^{q-1} \sum_{i=1}^N q_i^{l+1} (y_i^{l+1} - y_i^l) - \\
&- \Delta t \sum_{l=0}^{q-1} \sum_{i=1}^N q_i^{l+1} \left(-(v_i^l)^2 x_i^l - \varepsilon \left(1 - \beta_i(x_i^l)^2 \right) + u_i^l + \sum_{j=1}^N w_{ij}^l (y_j^{l-\tau_j} - y_i^l) \right).
\end{aligned}$$

Вычислим градиент минимизируемой функции:

$$\frac{\partial L}{\partial u_k^m} = \lambda_0 M_1 \Delta t \frac{\partial f_0(t, x^m, u^m, w^m)}{\partial u_k^m} - q_k^{m+1} \Delta t,$$

$$k = \overline{1, N}, \quad m = \overline{0, q-1}.$$

Условия стационарности по фазовым переменным имеют вид:

$$\frac{\partial L}{\partial x_k^m} = \lambda_0 M_1 \Delta t \frac{\partial f_0(t, x^m, u^m, w^m)}{\partial x_k^m} + p_k^m - p_k^{m+1} + \quad (2.14)$$

$$+ 2(v_k)^2 q_k^{m+1} \Delta t - 2\Delta t q_k^{m+1} \varepsilon \beta_k x_k^m = 0,$$

$$\frac{\partial L}{\partial x_k^q} = \lambda_0 M_2 \Delta t \frac{\partial \Phi(x^q)}{\partial x_k^q} + p_k^q = 0, \quad (2.15)$$

$$\frac{\partial L}{\partial y_k^m} = -p_k^{m+1} \Delta t + q_k^m - q_k^{m+1} - \quad (2.16)$$

$$-\Delta t \sum_{i=1}^N q_i^{m+\tau_k+1} w_{ik}^m + q_k^{m+1} \Delta t \sum_{i=1}^N w_{kj}^m = 0,$$

$$\frac{\partial L}{\partial y_k^q} = q_k^q = 0, \quad k = \overline{1, N}, \quad m = \overline{0, q-1}. \quad (2.17)$$

Выражая из условий (2.14)–(2.17) векторы $p_k^m, p_k^q, q_k^m, q_k^q$, получим рекуррентные соотношения для вычисления сопряженных переменных:

$$p_k^m = -\lambda_0 M_1 \Delta t \frac{\partial f_0(t, x^m, u^m, w^m)}{\partial x_k^m} + p_k^{m+1} - \quad (2.18)$$

$$-(v_k)^2 q_k^{m+1} \Delta t + 2\Delta t q_k^{m+1} \varepsilon \beta_k x_k^m,$$

$$p_k^q = -\lambda_0 M_2 \Delta t \frac{\partial \Phi(x^q)}{\partial x_k^q}, \quad (2.19)$$

$$q_k^m = p_k^{m+1} \Delta t + q_k^{m+1} + \Delta t \sum_{i=1}^N q_i^{m+\tau_k+1} w_{ik}^m - q_k^{m+1} \Delta t \sum_{i=1}^N w_{kj}^m, \quad (2.20)$$

$$\text{при } m \geq q, q_k^m = 0. \quad (2.21)$$

Полученные рекуррентные соотношения (2.18)–(2.21) могут быть использованы в численном алгоритме обучения искусственной нейронной сети методом градиентного спуска.

Заключение

Таким образом, построенная дискретная модель искусственной нейронной сети может быть успешно использована для аппроксимации моделей управляемых процессов, описываемых системой дифференциальных уравнений с запаздывающим аргументом. Предложенный подход эффективен при решении широкого класса прикладных задач, включая разработку робототехнических систем, систем распознавания образов, прогнозирования и др. [Галушкин, 2012]. Применение для моделирования процесса обучения искусственной нейронной сети динамической модели, описываемых системой дифференциальных уравнений, обеспечивает возможность получения высокой точности численного решения с низкими временными затратами на проведение вычислений. Благодаря своему быстродействию, нейросетевые системы обработки информации имеют значительные преимущества при проведении вычислений в режиме реального времени.

Список литературы

- [**Андреева 2015**] Андреева Е.А., Краевич П.В. Оптимизация нейронных сетей. – Тверь: Твер. гос. ун-т, 2015. – 116 с.
- [**Лебедев 2019**] Лебедев Б.К., Лебедев О.Б., Жиглатый А.А. Способы повышения устойчивости задачи обучения искусственных нейронных сетей при сохранении сходимости // Информатика, вычислительная техника и инженерное образование. – 2019. – № 2(35). – С. 50-56.
- [**Андреева 2006**] Андреева Е.А., Цирулева В.М. Вариационное исчисление и методы оптимизации. – М.: Высшая школа, 2006. – 584 с.
- [**Евтушенко 1982**] Евтушенко Ю.Г. Методы решения экстремальных задач и их применение в системах оптимизации. – М.: 1982. – 432 с.
- [**Галушкин 2012**] Галушкин А.И. Нейронные сети. Основы теории. – М.: Горячая линия – Телеком, 2012. – 496 с.

УДК 004.827

НЕЧЕТКИЕ МОДЕЛИ КАК ФОРМАЛИЗАЦИЯ ОЦЕНОЧНЫХ ЗНАНИЙ ЭКСПЕРТОВ

Г.Э. Яхьяева (*gul_nara@mail.ru*)

О.Д. Пальчунова (*o.palchunova@g.nsu.ru*)

Новосибирский государственный университет, Новосибирск

Оценочные знания о предметной области возможно представлять не только в виде объективной (статистической) вероятности, но также в виде субъективной (экспертной) вероятности. Экспертные оценки могут быть неполными, несогласованными между собой. Необходим инструмент проверки согласованности экспертных знаний. В работе предложена формализация субъективной интерпретации вероятности на языке теории нечетких моделей. Это позволяет сформулировать критерии согласованности оценочных знаний, полученных от экспертов. В статье описываются различные свойства согласованных оценочных знаний, рассматривается понятие минимальной нечеткой модели, согласованной с данным оценочным знанием, исследуются критерии единственности такой модели.

Ключевые слова: нечеткая модель, оценочные знания, согласование знаний.

Введение

На сегодняшний день выделяются три основных концепции интерпретации вероятности [Нажек, 2003]: эпистемологическая концепция, концепция объективной вероятности и концепция субъективной вероятности. Основная идея эпистемологического подхода состоит в симметричности мира, т.е. в равномерном распределении вероятности между всеми возможными элементарными исходами испытания [Bienvenu et al., 2009].

Однако реальный (физический) мир в большинстве своих проявлениях не симметричен. Даже в известной задаче о подбрасывании игральной кости элементарные исходы будут не равновероятны, если игральная кость будет утяжелена с одной стороны [Карнап, 1971]. Таким образом, на смену классической интерпретации вероятности приходит понятие частотной или статистической вероятности. Такая вероятность представляет

собой определенную интеграцию имеющихся знаний, т.е. в прошлом мы имеем ряд испытаний, в которых данное событие либо произошло, либо нет. На основании этого опыта мы делаем статистические выводы.

В отличие от объективной, субъективную вероятность можно интерпретировать как предсказание наступления в будущем некоторого события, для которого либо мы не обладаем статистическими данными, либо по тем или иным причинам данное событие невозможно повторить [Shafer, 2016]. Например, утверждение «в ближайшие десять лет кто-нибудь приземлится на Марсе с вероятностью 0,9» носит субъективный характер, так как это событие является одиночным, для которого невозможно собрать статистику. В связи с этим, объективную вероятность иногда называют вероятностью прошлого, а субъективную вероятность – вероятностью будущего [Gillies, 2006].

Б.А. Кобринский отмечал три основных направления применения методологии субъективной вероятности в интеллектуальных системах [Кобринский, 1997]:

- 1) учет в базе знаний интуитивных представлений специалиста, например, проявляющихся в форме ассоциаций;
- 2) отображение в формализмах базы знаний уверенности эксперта (группы экспертов) в знаниях;
- 3) отражение на входе системы того, что можно характеризовать термином «сомнения» в пропущенных через мозг специалиста в проблемной области объективных признаках и/или субъективных сведениях.

Факторы уверенности, отражающие динамику проявления признаков, включая образные, и учитывающие степень выраженности лингвистических и визуальных представлений, являются условием повышения надежности решений нечетких интеллектуальных систем [Кобринский, 2017].

Таким образом, субъективная вероятность представляет собой степень веры конкретного человека (или группы людей) в наступление определенного события. В связи с этим выделяются следующие проблемы при использовании субъективных вероятностей [Cohen, 1956]:

- поскольку речь идет только о личных мнениях, обычно существует высокая степень личной предвзятости;
- оценки одного события разными людьми могут очень сильно отличаться друг от друга;
- оценки различных событий должны подчиняться определенным условиям, чтобы быть работоспособными. Например, вы не можете думать, что сегодня будет дождь с вероятностью 0,75, и при этом думать, что дождя не будет с вероятностью 0,75.

Решение первых двух проблем обычно производят эмпирическим путем, т.е. собирают оценки одного и того же события разными экспертами, а затем вычисляют среднюю арифметическую или среднюю взвешенную оценку.

Необходимость решать третью проблему также подтверждает так называемая «теорема Голландской книги» (Dutch Book Theorem). Впервые этот термин был введен в работе [Lehman, 1955]. Автор предложил ассоциировать субъективную вероятность со ставками на скачках. Тогда, если полученные оценочные знания будут нарушать аксиомы Колмогоровского исчисления вероятностей, то всегда существует стратегия букмекера, при которой игрок будет в проигрыше, независимо от результатов скачек [Diniz et al., 2017].

В данной работе мы предлагаем теоретико-модельный подход к решению проблемы совместной корректности оценочных (субъективных) знаний. Данный подход основывается на теории нечетких моделей [Пальчунов и др., 2010; Пальчунов и др., 2015] и согласуется с четырехуровневой моделью представления знаний [Palchunov et al., 2017a].

В первом параграфе мы дадим определение нечеткой модели и опишем свойства нечетких моделей, которые понадобятся для дальнейшего изложения. Доказательства этих свойств можно найти в работах [Palchunov et al., 2017b; Palchunov et al., 2019; Yakhyaeva et al., 2021].

Второй параграф статьи посвящен формализации задачи проверки корректности набора оценочных знаний, т.е. согласованности этого набора с некоторой нечеткой моделью.

При построении нечеткой модели, согласованной с субъективными оценками, встает проблема неоднозначности описания такой модели. В третьем параграфе описываются минимальные нечеткие модели, согласованные с данным набором оценочных знаний.

1. Нечеткие модели

Зафиксируем сигнатуру σ , т.е. множество понятий, на языке которых описывается данная предметная область. Для простоты изложения будем считать, что сигнатура σ не содержит функциональных символов, т.е. состоит из не более, чем счетного числа предикатных символов и не более, чем счетного числа константных символов.

Пусть A – множество объектов моделируемой предметной области. Введем дополнительное множество констант $C = \{c_a \mid a \in A\}$ и обозначим $\sigma_A = \sigma \cup C$. Тогда любое событие предметной области можно формализовать в виде некоторого предложения φ сигнатуры σ_A . Обозначим через $S(\sigma_A)$ множество всех предложений сигнатуры σ_A , т.е. множество всевозможных событий данной предметной области.

Введем также следующие обозначения:

$S_\alpha(\sigma) = \{\alpha_1, \alpha_2, \dots\}$ – множество атомарных предложений сигнатуры σ .

$S_\beta(\sigma) = \{\bigwedge_{i=1}^n \varepsilon_i \alpha_i \mid \varepsilon_i \in \{\emptyset, \neg\}, \alpha_i \in S_\alpha(\sigma), n = \|S_\alpha(\sigma)\|\}$ – множество всех максимальных конъюнктов сигнатуры σ .

Определение 1. *Тройку $\mathfrak{A}_\mu = \langle A, \sigma, \mu \rangle$ будем называть **нечеткой моделью**, если*

1. *Отображение $\mu: S(\sigma_A) \rightarrow [0,1]$ является нечеткой, счетно-аддитивной мерой;*

2. *$\varphi \sim \psi \Rightarrow \mu(\varphi) = \mu(\psi)$, для любых $\varphi, \psi \in S(\sigma_A)$.*

Под нечеткой мерой мы понимаем отображение, отвечающее следующему условию [Beliakov, 2020]:

$$(A1) \quad \mu(\mathbf{0}) = 0; \mu(\mathbf{1}) = 1.$$

Из счетной аддитивности и свойства (2) выводится свойство *монотонности*:

$$(A2) \quad \varphi \leq \psi \Rightarrow \mu(\varphi) \leq \mu(\psi), \text{ для любых } \varphi, \psi \in S(\sigma_A),$$

где $\varphi \leq \psi \Leftrightarrow \varphi \sim \varphi \ \& \ \psi$.

Заметим, что для любой счетной последовательности предложений $\varphi_1, \varphi_2, \varphi_3 \dots \in S(\sigma_A)$ выполняется

$$\varphi_1 \leq (\varphi_1 \vee \varphi_2) \leq (\varphi_1 \vee \varphi_2 \vee \varphi_3) \leq \dots$$

Следовательно, по свойству (A2) получим

$$\mu(\varphi_1) \leq \mu(\varphi_1 \vee \varphi_2) \leq \mu(\varphi_1 \vee \varphi_2 \vee \varphi_3) \leq \dots$$

Так как данная последовательность ограничена, то получаем свойство, которое в литературе часто называют *свойством непрерывности*:

$$(A3) \quad \mu\left(\bigvee_{i \in \mathbb{N}} \varphi_i\right) = \lim_{n \rightarrow \infty} \left(\bigvee_{i=1}^n \varphi_i\right).$$

Аналогичными рассуждениями получаем второе свойство непрерывности:

$$(A4) \quad \mu\left(\bigwedge_{i \in \mathbb{N}} \varphi_i\right) = \lim_{n \rightarrow \infty} \left(\bigwedge_{i=1}^n \varphi_i\right).$$

В частности, это позволяет определять меру предложений с кванторами:

$$(A3)' \quad \mu(\exists x\psi(x)) = \mu\left(\bigvee_{a \in A} \psi(a)\right).$$

$$(A4)' \quad \mu(\forall x\psi(x)) = \mu\left(\bigwedge_{a \in A} \psi(a)\right).$$

Заметим, что если нечеткая модель \mathfrak{A}_μ является конечной (т.е. $\|A\| < \omega$), то каждое предложение $\varphi \in S(\sigma_A)$ содержащие кванторы, эквивалентно некоторому бескванторному предложению $\varphi' \in S(\sigma_A)$. Таким образом, при выполнении свойства (2) из Определения 1, нам достаточно потребовать, чтобы мера $\mu: S(\sigma_A) \rightarrow [0,1]$ была конечно-аддитивной.

Также заметим, что если помимо условия $\|A\| < \omega$ выполняется также условие конечности сигнатуры предметной области (т.е. $\|\sigma\| < \omega$), то пара $(S_\beta(\sigma_A), S(\sigma_A))$ будет являться -алгеброй, а тройка $(S_\beta(\sigma_A), S(\sigma_A), \mu)$ – векторным пространством.

Будем говорить, что предложение $\varphi \in S(\sigma_A)$ истинно на нечеткой модели \mathfrak{A}_μ , если $\mu(\varphi) = 1$. Очевидно, что любое тождественно истинное предложение является истинным на любой нечеткой модели. Таким образом, понятие нечеткой модели является консервативным расширением понятия модели в классической логике предикатов. Более того, если мера μ тривиальная (т.е. является отображением в двухэлементное множество $\{0, 1\}$), то нечеткая модель \mathfrak{A}_μ является моделью классической логики предикатов.

2. Субъективные знания эксперта

Задавая нечеткую модель \mathfrak{A}_μ как формализацию предметной области, мы должны располагать знанием о субъективной вероятности всех предложений множества $S(\sigma_A)$. Однако эксперт (или даже группа экспертов) может не обладать таким полным знанием. Более того, как было отмечено выше, множество $S(\sigma_A)$ может оказаться бесконечным. Тем не менее, существует конечное множество событий предметной области S , о вероятностных значениях которых эксперт может дать свою субъективную оценку.

Рассмотрим множество предложений S . Обозначим через σ_S сигнатуру множества предложений S .

Определение 2. Рассмотрим множество предложений S и отображение $\eta_S: S \rightarrow [0,1]$. Означивание η_S *согласуется* с нечеткой моделью $\mathfrak{A}_\mu = \langle A, \sigma_S, \mu \rangle$, если для любого предложения $\varphi \in S$ выполняется равенство $\eta_S(\varphi) = \mu(\varphi)$.

Означивание назовем **согласованным**, если существует нечеткая модель сигнатуры σ_S , с которой данное означивание согласуется.

Заметим, что понятия согласованности и непротиворечивости не совпадают. Для демонстрации этого рассмотрим следующий пример. Пусть $S = \{P(c), \neg P(c)\}$. Очевидно, что множество S противоречиво. Однако означивание η'_S , определенное следующим образом:

$$\eta'_S(P(c)) = 0,6; \eta'_S(\neg P(c)) = 0,4;$$

является согласованным. А означивание

$$\eta'_S(P(c)) = 0,6; \eta'_S(\neg P(c)) = 0,3;$$

несогласованно. Это следует из того, что с одной стороны для любой нечеткой модели \mathfrak{M} и для любых предложений φ и ψ сигнатуры этой модели должно выполняться условие [Yakhyayeva, 2007]:

$$\mu(\varphi \& \psi) \in \left[\max(0, 1 - (\mu(\varphi) + \mu(\psi))); \min(\mu(\varphi); \mu(\psi)) \right].$$

А с другой стороны, так как $(P(c) \& \neg P(c)) \sim \mathbf{0}$, то $\mu(P(c) \& \neg P(c)) = 0$.

Предложение 1. Для любого множества предложений S всегда существует согласованное означивание.

Доказательство. Заметим, что любая модель логики предикатов является частным случаем нечеткой модели. Рассмотрим некоторую (классическую) модель \mathfrak{M} сигнатуры σ_S . Очевидно, что для любой сигнатуры всегда существует такая модель.

Определим означивание η_S следующим образом: $\eta_S(\varphi) = 1$ тогда и только тогда, когда предложение φ истинно на модели \mathfrak{M} , и $\eta_S(\varphi) = 0$ тогда и только тогда, когда предложение φ ложно на модели \mathfrak{M} .

Предложение доказано.

Предложение 2. Если предложение $\varphi \in S$ является тождественно истинным (тождественно ложным), то необходимым условием согласованности означивания η_S является условие: $\mu(\varphi) = 1$ ($\mu(\varphi) = 0$).

Доказательство следует непосредственно из Определения нечеткой модели.

Далее означивание η_S будем называть **тривиальным**, если оно является отображением в двухэлементное множество $\{0, 1\}$.

Следствие 1. Если в множество S входит хотя бы одно выполнимо-опровержимое предложение, то для множества S существует нетривиальное и невырожденное согласованное означивание.

Теорема 1. Пусть S конечное множество атомарных предложений, (т.е. $S = S_\alpha(\sigma)$, где $\|\sigma\| < \omega$), то любое означивание $\eta_S: S \rightarrow [0,1]$ является согласованным.

Доказательство. Рассмотрим конечное множество атомарных предложений $S = \{\varphi_0, \varphi_1, \dots, \varphi_n\}$ и означивание $\eta_S: S \rightarrow [0,1]$. Упорядочим множество S так, чтобы выполнялось условие:

$$\eta_S(\varphi_0) \geq \eta_S(\varphi_1) \geq \dots \geq \eta_S(\varphi_n).$$

Пусть σ_S сигнатура множества S и $C_S \subseteq \sigma_S$ – множество констант сигнатуры σ_S . Так как все предложения из S бескванторные, то $C_S \neq \emptyset$.

Зададим нечеткую модель $\mathfrak{M}_\mu = \langle C_S, \sigma_S, \mu \rangle$. Так как, по условию Теоремы, модель \mathfrak{M}_μ будет конечной моделью конечной сигнатуры, то она эквивалентна вероятностному пространству $(S_\beta(\sigma_S), S(\sigma_S), \mu)$. Таким образом, для полного описания нечеткой модели \mathfrak{M}_μ нам достаточно задать отображение $\mu: S_\beta(\sigma_S) \rightarrow [0, 1]$, отвечающее следующим условиям:

- (1) Для любого предложения $\beta \in S_\beta(\sigma_S)$ имеем $0 \leq \mu(\beta) \leq 1$;
- (2) $\sum_{\beta \in S_\beta(\sigma_S)} \mu(\beta) = 1$.

Зададим отображение $\mu: S_\beta(\sigma_S) \rightarrow [0,1]$ следующим образом:

$$\begin{aligned} \mu(\varphi_0 \& \varphi_1 \& \dots \& \varphi_{n-1} \& \varphi_n) &= \eta_S(\varphi_n); \\ \mu(\varphi_0 \& \dots \& \varphi_{n-1} \& \neg \varphi_n) &= \eta_{S(\varphi_{n-1})} - \eta_S(\varphi_n); \\ &\dots \\ \mu(\varphi_0 \& \dots \& \varphi_k \& \neg \varphi_{k+1} \& \dots \& \neg \varphi_n) &= \eta_{S(\varphi_k)} - \eta_S(\varphi_{k+1}); \\ &\dots \\ \mu(\neg \varphi_0 \& \dots \& \neg \varphi_{n-1} \& \neg \varphi_n) &= 1 - \eta_S(\varphi_0). \end{aligned}$$

По построению очевидно, что условие (1) выполняется. Покажем, что условие (2) также выполняется.

Очевидно, что $\mathbf{1} \sim \bigvee_{\beta \in S_\beta(\sigma_S)} \beta$. Тогда, в силу свойства аддитивности, получим

$$\mu(\mathbf{1}) = \sum_{\beta \in S_{\beta}(\sigma_S)} \mu(\beta) = \eta_S(\varphi_n) + (\eta_S(\varphi_{n-1}) - \eta_S(\varphi_n)) + \dots + (1 - \eta_S(\varphi_0)) = 1.$$

Для завершения доказательства Теоремы, нам осталось показать, что построенная модель \mathfrak{M}_μ согласуется с означиванием η_S . Для этого необходимо показать, что для любого атомарного предложения $\varphi_k \in S$ имеет место равенство: $\mu(\varphi_k) = \eta_S(\varphi_k)$.

Очевидно, что

$$\varphi_k \sim \bigvee_{\varepsilon_1, \dots, \varepsilon_n \in \{\emptyset, \neg\}} (\varepsilon_1 \varphi_1 \& \dots \& \varepsilon_{(k-1)} \varphi_{k-1} \& \varphi_k \& \varepsilon_{(k+1)} \varphi_{k+1} \& \dots \& \varepsilon_n \varphi_n).$$

Выкидывая дизъюнкты, значение функции μ на которых равно нулю, получим

$$\begin{aligned} \mu(\varphi_k) &= \mu(\varphi_0 \& \dots \& \varphi_{n-1} \& \varphi_n) + \mu(\varphi_0 \& \dots \& \varphi_{n-1} \& \neg \varphi_n) + \dots \\ &\quad + \mu(\varphi_0 \& \dots \& \varphi_k \& \neg \varphi_{k+1} \& \dots \& \neg \varphi_n) = \\ &= \eta_S(\varphi_n) + (\eta_S(\varphi_{n-1}) - \eta_S(\varphi_n)) + \dots + (\eta_S(\varphi_k) - \eta_S(\varphi_{k+1})) = \eta_S(\varphi_k). \end{aligned}$$

Теорема доказана.

3. Минимально согласованные нечеткие модели

Заметим, что в Теореме 1, при построении нечеткой модели $\mathfrak{M}_\mu = \langle A, \sigma_S, \mu \rangle$, согласованной с означиванием η_S мы определяли основное множество A модели \mathfrak{M}_μ равное множеству констант C_S сигнатуры σ_S . Однако, если множество S содержит предложения с кванторами, то множества констант может оказаться недостаточным для определения согласованной модели. Например, рассмотрим множество предложений $S = \{P(c), \exists x P(x)\}$ с означиванием

$$\eta_S(P(c)) = 0,3; \eta_S(\exists x P(x)) = 0,5.$$

Очевидно, что данное означивание не может согласовываться ни с какой одноэлементной нечеткой моделью. Для возможности согласования необходимо по крайней мере два элемента a_1 и a_2 такие, что

$$\mu(P(a_1)) = 0,3; \mu(P(a_2)) = 0,5.$$

При описании предметной области иногда требуется определить не только согласованность экспертных знаний, но и какое минимальное количество объектов предметной области нужно иметь, чтобы означивание стало согласованным.

В качестве примера рассмотрим задачу составления комплекта олимпиадных задач. Допустим, что у нас есть три экспертных оценки:

- Задачу a решит 50% процентов участников олимпиады.
- Либо задачу a , либо задачу b решит 65% участников олимпиады.
- Задачу a и задачу c решат 20% участников олимпиады.

А также пусть у нас есть требование администрации:

- Составить комплект так, чтобы хотя бы одну задачу решит 90% участников
- Составить комплект так, чтобы все задачи решит 10% участников олимпиады.

Таким образом, на входе у нас есть множество

$$S = \{P(a), P(a) \vee P(b), P(a) \& P(c), \exists x P(x), \forall x P(x)\}$$

с ответствующим означиванием η_S :

$$\langle 0,5; 0,65; 0,2; 0,9; 0,1 \rangle.$$

Нам необходимо проверить, а возможно ли в принципе составить комплект задач, удовлетворяющих этим условиям. И если такое возможно, то сколько как минимум нужно задач, чтобы удовлетворить этим требованиям.

Мы выделяем сигнатуру $\sigma_S = \{P, a, b, c\}$. Для ответа на первый вопрос, нам нужно проверить, существует ли нечеткая модель $\mathfrak{M}_\mu = \langle A, \sigma_S, \mu \rangle$, согласованная с означиванием η_S . Основное множество A модели \mathfrak{M}_μ – это набор задач, входящих в комплект. Очевидно, что $\{a, b, c\} \subseteq A$. И для ответа на второй вопрос нам нужно определить, какова должна быть минимальная мощность множества A .

В данной конкретной задаче означивание η_S является согласованным и комплект задач должен состоять как минимум из 5 различных задач, т.е. помимо задач a, b, c необходимо включить еще не меньше двух задач. (Проверку этого факта оставляем читателю).

Заметим, что если бы второе требование администрации звучало так: «все задачи решит 20% участников олимпиады», то минимальное необходимое число задач было бы равно четырем.

Для формализации данной проблемы будем использовать понятие элементарной подмодели.

Определение 3. Пусть $\mathfrak{M}_{\mu_1} = \langle A_1, \sigma, \mu_1 \rangle$ и $\mathfrak{M}_{\mu_2} = \langle A_2, \sigma, \mu_2 \rangle$ нечеткие модели одной сигнатуры σ . Будем говорить, что нечеткая модель \mathfrak{M}_{μ_1} является элементарной подмоделью нечеткой модели \mathfrak{M}_{μ_2} (обозначение $\mathfrak{M}_{\mu_1} \leq \mathfrak{B}_{\mu_2}$), если выполняются следующие условия:

1. $A_1 \subseteq A_2$;

2. Для любой константы $c \in \sigma$ имеет место $c^{\mathfrak{A}_{\mu_1}} = c^{\mathfrak{B}_{\mu_2}}$.
3. Для любого предложения $\varphi \in S(\sigma_{A_1})$ имеет место $\mu_1(\varphi) = \mu_2(\varphi)$.

Очевидно, что если нечеткая модель \mathfrak{A}_μ сигнатуры σ_S согласуется с означиванием η_S , то любая элементарная подмодель модели \mathfrak{A}_μ так же будет согласовываться с означиванием η_S . Более того, пересечение элементарных подмоделей модели \mathfrak{A}_μ также будет образовывать нечеткую модель, согласованную с означиванием η_S . Таким образом, мы приходим к понятию минимальной нечеткой модели, согласованной с данным означиванием η_S .

Определение 4. *Нечеткую модель \mathfrak{A}_μ будем называть m -согласованной (или минимально согласованной) с означиванием η_S , если модель \mathfrak{A}_μ согласована с означиванием η_S и не существует элементарной подмодели модели \mathfrak{A}_μ также согласованной с означиванием η_S .*

Заметим, что не для каждого множества предложений S и означивания η_S существует m -согласованная нечеткая модель. Например, пусть множество S состоит из единственного предложения

$$\varphi = \forall x \exists y P(x, y) \ \& \ \forall x \forall y (\neg P(x, y) \vee \neg P(y, x)) \ \& \ \forall x \forall y \forall z ((P(x, y) \ \& \ P(y, z)) \rightarrow P(x, z)).$$

Очевидно, что в классической логике предикатов это предложение ложно на всех конечных моделях. Следовательно, если $\eta_S(\varphi) > 0$, то модель \mathfrak{A}_μ , согласованная с означиванием η_S всегда будет бесконечной. И, более того, не существует наименьшей элементарной подмодели этой модели.

Предложение 3. *Рассмотрим множество предложений S и означивание η_S . Если существует хотя бы две неизоморфные нечеткие модели, определенные на одном и том же основном множестве A и согласованные с означиванием η_S , то таких моделей существует бесконечно много.*

Доказательство. Пусть нечеткие модели $\mathfrak{A}_{\mu_1} = \langle A, \sigma, \mu_1 \rangle$ и $\mathfrak{A}_{\mu_2} = \langle A, \sigma, \mu_2 \rangle$ согласованы с означиванием η_S . Нетрудно проверить, что отображение $\mu = \frac{\mu_1 + \mu_2}{2}$ также будет нечеткой, счетно-аддитивной мерой, а модель $\mathfrak{A}_\mu = \langle A, \sigma, \mu \rangle$ будет согласована с означиванием η_S .

Предложение доказано.

Предложение 4. Пусть $S = S_\beta(\sigma)$ для некоторой конечной сигнатуры σ . Тогда означивание η_S согласовано тогда и только тогда, когда выполняется условие

$$\sum_{\omega \in S} \eta_S(\omega) = 1.$$

Более того, означивание η_S будет иметь единственную m -согласованную модель.

Доказательство. Пусть $C \subset \sigma$ – множество констант сигнатуры σ . Очевидно, что $C \neq \emptyset$. Тогда означивание η_S однозначно задает вероятностное пространство, определенное на σ -алгебре $(S_\beta(\sigma), S(\sigma_C))$. И, в силу конечности сигнатуры σ , это вероятностное пространство будет эквивалентно нечеткой модели $\mathfrak{M} = \langle C, \sigma, \mu \rangle$.

Предложение доказано.

Введем следующее обозначение:

$S_\gamma(\sigma) = \{\bigwedge_{\alpha \in S'} \alpha \mid S' \subseteq S_\alpha(\sigma)\}$ – множество всех положительных конъюнктов сигнатуры σ .

Предложение 5. Пусть $S = S_\gamma(\sigma)$ для некоторой конечной сигнатуры σ . Тогда означивание η_S согласовано тогда и только тогда, когда для любых $S_1, S_2 \subseteq S_\gamma(\sigma)$ выполняется условие

$$S_1 \subseteq S_2 \Rightarrow \eta_S \left(\bigwedge_{\alpha \in S_2} \alpha \right) \leq \eta_S \left(\bigwedge_{\alpha \in S_1} \alpha \right).$$

Более того, означивание η_S будет иметь единственную m -согласованную модель.

Доказательство. Пусть $C \subset \sigma$ – множество констант сигнатуры σ . Очевидно, что $C \neq \emptyset$. В статье [Yakhyaeva, 2009] было доказано, что для любой нечеткой, аддитивной меры $\mu: S(\sigma_C) \rightarrow [0,1]$ мера каждого предложения $\omega \in S_\beta(\sigma)$ является линейной комбинацией мер некоторых предложений из $S_\gamma(\sigma)$. Таким образом, по означиванию множества предложений $S_\gamma(\sigma)$ мы однозначно восстанавливаем означивание множества предложений $S_\beta(\sigma)$.

Предложение доказано.

Заметим, что в Предложениях 4 и 5 мощность множества S равна $2^{\|S_\alpha(\sigma)\|}$, где $S_\alpha(\sigma)$ – множество всех атомарных предложений сигнатуры σ . Таким образом, можно выдвинуть гипотезу, что для того, чтобы однозначно

описать нечеткую модель, формализующую данную предметную область, нам необходимо иметь оценочные знания как минимум об 2^{k+l} событиях этой предметной области, где k – число объектов предметной области и l – число предикатов, описывающих данную предметную область.

Заключение

В работе описана теоретико-модельная формализация субъективной (экспертной) вероятности. Субъективная вероятность формализуется в виде нечеткой модели, которая является консервативным расширением понятия модели в классической логике предикатов. Проверка согласованности экспертных знаний заключается в определении нечеткой модели, в которую эти знания вкладываются. Если такой модели не существует, то полученные знания считаются некорректными с логической точки зрения.

Набор экспертных оценок является конечным и зачастую неполным. В связи с этим не всегда получается однозначно описать нечеткую модель, формализующую эти знания. В этом случае получается класс нечетких моделей, согласованных с данным набором экспертных оценок. В этом случае возникает проблема неоднозначности порождения новых оценочных знаний о предметной области.

В работе показано, что для однозначного описания нечеткой модели предметной области, мощность множества оценочных характеристик должна экспоненциально зависеть от мощности онтологии предметной области. Решение проблемы «взрыва размерности» мы видим в переходе от «точечных» оценок событий предметной области к интервальным оценкам этих событий. Одно из направлений дальнейших наших исследований мы видим в разработке формализации обобщенных нечетких моделей, значениями истинности на которых являются интервалы, определенные на отрезке $[0, 1]$.

Список литературы

- [Beliakov, 2020] Beliakov G., James S., Wu J.-Z. Discrete fuzzy measures: computational aspects. – Springer. 2020.
- [Bienvenu et al., 2009] Bienvenu, L., Shafer, G. and Shen, A. On the history of martingales in the study of randomness // J. Électron. Hist. Probab. Stat. – 2009. – Vol. 5. – P. 1-40.
- [Cohen, 1956] Cohen J., Hansel M. Risk and gambling: a study of subjective probability. – University of Calgary, 1956.
- [Diniz et al., 2017] Diniz, M.A., Gallo, S. The Beginnings of Axiomatic Subjective Probability / Polpo, A., Stern, J., Louzada, F., Izbicki, R., Takada, H. (eds) Bayesian Inference and Maximum Entropy Methods in Science and Engineering. maxent 2017. Springer Proceedings in Mathematics & Statistics. Vol 239. Springer.

- [Gillies, 2006] Gillies D. Subjective and Objective Probabilities in Medical Decision Making // Philosophy of Uncertainty and Medical Decisions, Bulletin of Life and Death Studies. – 2006. – Vol. 2.
- [Hajek, 2003] Hajek A. Interpretations of Probability // The Stanford Encyclopedia of Philosophy. – 2003.
- [Lehman, 1955] Lehman S. On Confirmation and Rational Betting // The Journal of Symbolic Logic. – 1955. – Vol. 20, No. 3.
- [Palchunov et al., 2017a] Palchunov D.E., Tishkovsky D.E., Tishkovskaya S.V., Yakhyaeva G.E. Combining logical and statistical rule reasoning and verification for medical applications // Proceedings - 2017 International Multi-Conference on Engineering, Computer and Information Sciences, SIBIRCON 2017, 18-22 September 2017, Novosibirsk, Russia.
- [Palchunov et al., 2017b] Palchunov D., Yakhyaeva G. Application of Boolean-valued models and FCA for the development of ontological model // CEUR Workshop Proceedings, 2017. № 1921.
- [Palchunov et al., 2019] Palchunov, D.E., Yakhyaeva G.E. Integration of Fuzzy Model Theory and FCA for Big Data Mining // SIBIRCON 2019 – International Multi-Conference on Engineering, Computer and Information Sciences, Proceedings. – 2019.
- [Shafer, 2016] Shafer G. Reconciling the subjective and objective aspects of probability // Statistical Science. – 2016. – 31 (4). – P. 552-554.
- [Yakhyaeva, 2007] Yakhyaeva G. Fuzzy model truth values // Proceedings of the 6-th International Conference Aplimat, February 6-9, 2007, Bratislava, Slovak Republic.
- [Yakhyaeva, 2009] Yakhyaeva G. Logic of fuzzifications // Proceedings of the 4th Indian International Conference on Artificial Intelligence, IICAI 2009. – 2009.
- [Yakhyaeva et al., 2021] Yakhyaeva G., Skokova V. Subjective Expert Evaluations in the Model-Theoretic Representation of Object Domain Knowledge // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). – 2021. – 12948 LNAI. – P. 152-165.
- [Карнап, 1971] Карнап Р. Философские основания физики. Введение в философию науки. – М.: Прогресс, 1971.
- [Кобринский, 1997] Кобринский Б.А. Подходы к отображению субъективно нечетких представлений эксперта и пользователя в интеллектуальных системах // Программные продукты и системы. – 1997. – № 4.
- [Кобринский, 2017] Кобринский Б.А. Нечеткость и факторы уверенности вербальных и визуальных экспертных знаний // Нечеткие системы, мягкие вычисления и интеллектуальные технологии (НСМВИТ-2017): Труды VII всероссийской научно-практической конференции (г. Санкт-Петербург, 3-7 июля, 2017 г.). – 2017.
- [Пальчунов и др., 2010] Пальчунов Д.Е., Яхьяева Г.Э. Нечеткие алгебраические системы // Вестник НГУ. Серия: Математика, механика, информатика. – 2010. – Т. 10. – Вып. 3.
- [Пальчунов и др., 2015] Пальчунов Д.Е., Яхьяева Г.Э. Нечеткие логики и теория нечетких моделей // Алгебра и логика. – 2015. – 54, № 1. – С. 109-118.

СЕКЦИЯ 4

**ПРИКЛАДНЫЕ
ИНТЕЛЛЕКТУАЛЬНЫЕ
СИСТЕМЫ.
ИНСТРУМЕНТАЛЬНЫЕ
СРЕДСТВА ПОСТРОЕНИЯ
ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ**

УДК 004.738.5: 621.391

**ИНТЕЛЛЕКТУАЛЬНЫЕ ИНФОРМАЦИОННЫЕ
ТЕХНОЛОГИИ В СОЕДИНЕНИЯХ
ВООРУЖЕННЫХ СИЛ**

Г.П. Виноградов (*wgp272ng@mail.ru*)
НИИ Центрпрограммсистем, Тверь,
Тверской государственный технический университет, Тверь

Интеллектуализация автоматизированных систем и комплексов в ВС РФ предполагает использование методов и технологий, основанных на знаниях. Это требует построение цикла инженерии знаний, включающего этапы восприятия, представления, осознания, пополнения знаний. В работе рассматривается один из ключевых этапов – этап приобретения знаний из распределенных источников. Предлагаемое решение основано на использовании средств SCADA и сенсорных сетей путем их интеграции, а также гибридизации со знаниями экспертов.

Ключевые слова: сенсорные сети, сенсорные узлы, паттерны, инженерия знаний, ситуационная осведомленность.

Введение

В настоящее время в передовых в военном отношении странах управлению информационными процессами при ведении боевых действий придается первостепенное значение. Современные информационные технологии позволяют концентрировать все виды информации при принятии адекватных боевой ситуации решений и реализовать новый подход к ведению боевых действий, основанный на интеграции систем всех уровней и родов войск. Вооруженные силы все в большей мере основываются на информационных технологиях и оснащаются высокоинтеллектуальными роботизированными системами (наземными, воздушными, морскими).

Сетевые информационные системы в вооруженных силах

Сетевые тактические информационные системы, обеспечивающие ситуационную осведомленность во всем стратегическом спектре боевых операций и принятие решений в условиях жестких временных ограничений, основа для превосходства над противником. Это качество достигается путем обработки максимально возможной совокупности мультимедийных и мультиспектральных данных в реальном времени. Оно позволяет реализовать адаптивное планирование боевых задач, вести целеуказание, оценку боевых потерь, оценивать надежность распределенных мобильных средств связи и т. п., как на уровне зоны проведения боевых операций, так и на уровне театра военных действий (ТВД). Для этого мобильное боевое информационное оборудование, тактические сетевые средства связи и спешенные оперативные средства управления, интегрируются с регулируемыми, устойчивыми и прозрачными для пользователя глобальными сетями, что соответствует философии «солдат как система».

Исследования возможности использования сенсоров совместно с беспроводной сетью положили начало развитию нового вида коммуникационных сетей под названием беспроводные сенсорные сети (БСС или англ. WSN). В настоящее время развитие таких сетей осуществляется в рамках концепции Интернета вещей [Cannon et al., 2007; Winkler et al., 2008; Lamont et al., 2011]. БСС рассматриваются как основа для сбора и обработки исходной информации для военных приложений. Прогресс в миниатюризации физических датчиков, встроенных микроконтроллеров и радиointерфейсов и интеграция их на одном чипе, развитие теории и практики беспроводных сетей привели к появлению нового поколения беспроводных сенсорных сетей. Они стали рассматриваться как одна из технологических основ *окружающего интеллекта*, способными собирать огромное количество информации из окружающей среды. В настоящее время сенсорные узлы оснащены достаточно мощным бортовым процессором, что

позволяет использовать их вычислительные мощности для локального выполнения простых вычислений при частичной обработке и передаче данных, также принятию решений в зоне своей ответственности.

Возможности военных приложений WSN зависят от средств контроля параметров среды. Наиболее важными являются: электромагнитные волны, свет, давление, звук, присутствие людей, объектов, наличие взрывоопасных паров, уровень химического и биологического заражения.

1. Примерная архитектура WSN военного назначения

Вариант многоуровневой архитектуры WSN для военных приложений может быть построен с использованием сенсорных узлов с радиосвязью ближнего действия и беспроводных шлюзов с беспроводной связью на большие расстояния. Она обеспечивает большую гибкость и расширяемость в возможных видах операций от небольшого одиночного кластера сенсорных узлов до множества соединений на площади до 20 км² [Lamont et al., 2011].

Сенсорные узлы находятся на первом уровне (tier-1) иерархии, где они выполняют основные операции мониторинга и воздействия на среду. Они оснащены встроенными преобразователями, такими как акустические, сейсмические, пассивные инфракрасные (PIR), магнитные и пьезоэлектрические и др. для обнаружения событий, представляющих интерес. При этом они способны подтвердить обнаружение, используя перекрестный поиск и выполнить классификацию. Каждый узел датчика в сети действует как маршрутизатор, пересылая пакеты данных на соседние узлы. Они формируют сеть «на лету» и поддерживают единый радиointерфейс для двунаправленной связи между узлами с датчиками и узлом слияния.

На втором уровне (tier-2) иерархии узлы слияния обеспечивают более сложные функции, такие как синхронизация базы данных, формирование кластера, формирование логики работы приложения и управление. Узлы слияния получают информационные запросы от пользователей, отслеживают команды, отвечают на запросы, формируют задачи узлам датчиков, собирают информацию и сохраняют историю событий, произошедших в зоне ответственности, охватываемой узлом слияния. Узлы fusion могут выступать в качестве исполнительных механизмов в сети, например, для запуска встроенной или близлежащей камеры для получения изображений, близких к реальному времени и пр. В отличие от типичной WSN, узлы слияния на втором уровне иерархии также образуют специальную сеть, обеспечивающую расширенный охват для более масштабной поддержки развертывания. Они оснащены несколькими радиointерфейсами для связи с узлами датчиков и другими узлами слияния, а также для передачи данных на большие расстояния на узел управления. Узлы датчиков и

узлы слияния образуют кластеры, которые соединяются между собой через головные узлы слияния для создания автоматической наземной сенсорной системы.

Узел управления (MN) на третьем уровне обеспечивает оперативный контроль и управление системой. Узел слияния на этом уровне использует канал дальней связи для связи с узлом управления. Авторизованные пользователи могут в соответствии с правом доступа получать доступ к системе с узлов слияния данных на уровне 2 или с узла управления на уровне 3. Используя портативное устройство, ноутбук или стационарный ПК, пользователь с надлежащей авторизацией может запрашивать события и подписываться на них, получать оповещения и просматривать историю действий системы.

2. Сенсорный узел

Сенсорный узел (MOT) может быть использован как для мониторинга среды, так и для локального или в составе группы воздействия на среду. В последнем случае он называется реагирующим. Его архитектура содержит пять основных компонент [Виноградов и др., 2021]: 1) сенсорная подсистема, включающая датчики и радар, для контроля состояния внешней среды с соответствующими аналого-цифровыми преобразователями; 2) подсистема обработки, включающая микроконтроллеры и память для хранения данных; 3) радиопередатчик для беспроводной передачи данных; 4) устройство электропитания; 5) подсистема исполнения решений.

В зависимости от конкретного применения сенсорные узлы могут включать в себя дополнительные компоненты, такие как систему позиционирования, мобилизатор, средства изменения местоположения и т.п. Сенсорные узлы образуют сенсорное поле, как правило, они находятся в *спящем* состоянии. Когда происходит событие, или по расписанию в определенное время, эти узлы *просыпаются*, самоорганизуются в сеть и передают информацию в центр сбора данных. Сенсорная сеть поддерживает основные интерфейсы и протоколы, которые применяются в настоящее время в глобальных и локальных сетях. Это позволяет интегрировать ее в существующую сеть.

Область применения WSN – это, как правило, неопределенные и плохо формализуемые среды, поэтому достичь желаемой эффективности подобных комплексов возможно, главным образом, путем совершенствования интеллектуальной составляющей их системы управления в целом и отдельным узлом в частности. Ситуация усугубляется требованиями скрытности, миниатюризации, малого энергопотребления. На практике требуется в качестве мота сети иметь автономный узел, который должен обладать свойством интеллектуального поведения: быть способным на изучение обстановки и принятию решений, как самостоятельно с учетом получаемых от других устройств сети данных, так и в составе группы.

3. Система управления узлом, использующая паттерны

Жесткие требования в ряде предметных областей к времени реагирования, объему памяти, быстродействию микрочипа и уровню энергопотребления предполагают использование сравнительно простых алгоритмов, построенных путем описания лучшего опыта человека при выполнении функциональных задач. В работах [Winkler et al., 2008; Lamont et al., 2011; Tafa et al., 2007] показано, что такое описание можно реализовать, если выявить классы типовых ситуаций и успешные способы действия в реальных условиях для формирования моделей поведения (паттернов). В работе [Виноградов и др., 2020] дана следующая обобщенная логическая схема описания паттерна

Имя паттерна:
так как [мотивы M]
поскольку [цели G]
если [предусловия U'] (1)
то способ действия $r_q(t)$
из-за чего [постусловие U'']
...
есть альтернатива [$r_p(t)$]

В этой модели все составляющие, кроме логических связок, могут представлять собой языковые конструкции на естественном или естественно-профессиональном языке. Следовательно, модель (1) – типовая естественно-языковая модель паттерна. Формальная модель паттерна поведения в типовой ситуации приведена в [Vinogradov, 2020]. Там же показано, что модель предметной области и модель принятия решений в условиях дефицита времени можно формализовать с помощью нечетких продукционных сетей. Мотивы в модели (1) – это причины, определяемые потребностями и/или обязательствами. Они побуждают агента к активности, в рамках которой потребовался паттерн. Описание мотивов и целей в модели (1) представляет контекст повторного применения паттерна с позиции необходимости и возможности его применения (потребности → мотивы → цели). Контекст определяется «ожидаемыми» постусловиями. Постусловия связаны с целями, затребовавшими паттерн, но отражают их в форме возможного состояния, к которому приведет применение паттерна. Цели определяют желаемое состояние и могут быть причиной, определяющей необходимость и полезность стремления к их достижению. Способ действия представляет собой код как естественно-языковое описание схемы действия, реализация которой приводит к выполнению паттерна. Такое описание имеет вид методик, реализованных на языке про-

граммирования. Набор моделей или паттернов поведения, образуют опыт или базу знаний его носителя. Модель индивидуального поведения автономного узла предполагает формирование базы паттернов на основе экспериментального опыта, что позволяет реализовать эволюцию «кооперативного интеллекта» благодаря использованию искусственного когнитивного процесса, аналогичного тому, что имеет место у естественных существ. Отметим, что эта возможность отсутствует в системах на основе знаний.

Для реализации описанного подхода разработан программно-технический комплекс, позволяющий производить моделирование среды (контекста) и паттерна поведения эксперта (агента) [Виноградов и др., 2021]. Выделены четыре базовые позиции моделирования, с которых осуществляется сбор и интерпретация информации для идентификации модели паттерна поведения. Первая позиция (собственная точка зрения человека), вторая позиция (восприятие ситуации с точки зрения экспериментатора), третья позиция (рассмотрение ситуации с точки зрения возможности использования формальных процедур), четвертая позиция восприятия подразумевает рассмотрение ситуации с точки зрения надсистемы, задействованной в ситуации.

Поскольку предполагается, что каждая позиция использует разные представления о ситуации и о возможных способах действия, то интегрирование точек зрения и их согласование позволяет агенту расширить свое понимание ситуации целеустремленного состояния и паттерна поведения в ней.

Моделирование из первой позиции заключается в том, чтобы человек, обладающий опытом выполнения миссии, реализует его в системе самостоятельно и исследует используемый при этом паттерн(ы). Испытуемый реализует свое поведение, осуществляя голосовое управление «аватаром» в трехмерном пространстве. Полученный управляющий код используется для вызова соответствующей процедуры для изменения поведения аватара. Для формирования сложного поведения аватар снабжен набором элементарных паттернов поведения: и базой знаний, с помощью которой он реализует так называемое реактивное поведение. Таким образом, моделируются функции лимбической системы, которая играет роль среднего мозга человека. С ее помощью мозг обнаруживает так называемые «значительные» стимулы, угрожающие выживанию, и посылает информацию телу, чтобы оно могло реагировать на них надлежащим образом, минуя сознание и используя встроенные реакции. И только потом изменения в теле фиксируются сознанием, вызывая соответствующую эмоциональную оценку. Например, реакции страха или гнева начинаются в лимбической системе, что вызывает диффузное влияние на симпатическую нервную систему (она регулирует расход энергоресурсов и мобилизует организм в

стрессовых ситуациях). Реакция организма, известная как «бей или беги», готовит человека к угрожающим ситуациям путем увеличения частоты его сердечных сокращений, дыхания или кровяного давления. В результате человек может в зависимости от обстоятельств защищаться или бежать. Аналогичным механизмом снабжен и аватар.

Архитектура интеллектуальной системы управления WSN имеет иерархическую структуру. Верхний уровень, реализуемый оператором, соответствует таким свойствам, как выживание, безопасность, выполнение обязательств согласно миссии, накопление и корректировка базы знаний в виде эффективных паттернов поведения. Объектом управления для нее является WSN, рассматриваемая как некоторая функциональная система. Она осуществляет: 1) расчет текущих показателей удельной ценности по результатам и эффективности в момент t [Виноградов и др., 2020]; 2) расчет и реализацию способа действия (поведения) в момент t согласно заданному паттерну поведения; 3) мониторинг результатов реализации паттерна поведения. Оператор обрабатывает паттерны поведения при выполнении миссии и выполняет анализ выполнения миссии. Узел рассчитывает последовательности состояний $y(t)$, реализует задачи миссии и выполняет расчет оценки удельной ценности и эффективности [Виноградов и др., 2020; Vinogradov, 2020] отработки фактических ситуаций. Такой подход к моделированию поведения узлов в сети на основе паттернов аналогичен подходу в прагматической эпистемологии, согласно которому знания рассматриваются как множество теорий или моделей, каждая из которых представляет собой описание поведения при решении определенного класса задач. Теории, описывающие класс явлений, могут «перекрываться», и возникает проблема выбора способа решения задач в конкретной предметной области. Критерием выбора становится ожидаемая удельная ценность возможного результата [Vinogradov, 2020]. Процесс получения знания в предлагаемой схеме аналогичен процессу биологической эволюции. Следовательно, критерием истинности знания искусственной сущности является «*приспособленность*» знания для решения задач предметной области.

4. Описание классов военного применения WSN

Самовосстанавливающиеся наземные мины (SHLM): WSN может быть основой в интеллектуальной системе минно-взрывного заграждения. Каждая мина отслеживает состояние своего соседа, чувствует угрозы для себя и автономно реагирует на эти угрозы, имеет возможность перемещения. Контроль обстановки основан, например, на распределенной автономной акустической системе определения местоположения и датчиках акселерометра [Adams et al., 2007; Виноградов и др., 2022].

WSNs, носителями узлов которых являются солдаты. Одним из перспективных направлений военного применения WSN для контроля состояния оператора являются нательные сенсорные сети (БНСС) [Merrill et al., 2005]. Они представляют собой набор сенсорных узлов, расположенных на теле и внутри тела человека, взаимодействующие между собой и координирующим узлом посредством беспроводной связи на основе стандартов IEEE 802.15.16 [Naz et al., 2012; Towle et al., 2007] или IEEE 802.15.4/ZigBee на основе MAC. В качестве датчиков используются датчики кровяного давления, пульса, мониторинга сахара в крови температуры тела, пульсовой оксиметрии, частоты дыхания и т.д. Приложение с подобной функциональностью предназначено для отслеживания жизненно важных функций солдата и выявления его состояния при серьезном поражении или риске летального исхода. Такие сети имеют большой потенциал для систем контроля и управления состоянием операторов РЛС в средствах радиоэлектронной разведки, а также контроля состояния личного состава при выполнении специальных операций.

Обнаружение и отслеживание солдат (SDT): При защите военных объектов или зданий автономные акустические и сейсмические датчики позволяют путем обследования определенных точек обнаруживать проникновение диверсантов [Виноградов и др., 2022]. Приложение для слежения за человеком использует смесь акустических датчиков и камер визуализации. Интеграция между акустической и визуальной модальностями приводит к активации камеры только в нужное время и в нужном месте. Сеть передает только те изображения, которые согласуются с акустически генерируемыми треками, обеспечивающие очень высокую частоту попаданий [Riprin et al., 2012].

Акустические датчики для прибрежной противолодочной обороны (ASW): Концепция ASW использует небольшие датчики с пассивным и активным гидролокатором для обнаружения современных дизельных подводных лодок, работающих от батарей. Датчики могут быть установлены в большом количестве (сотни или тысячи), чтобы обеспечить высокую плотность сенсорного поля. Датчики имеют небольшую дальность обнаружения и, следовательно, гораздо менее чувствительны к многолучевым отражениям и другим акустическим артефактам [Towle et al., 2007].

Система обнаружения и локализация снайпера (SDL): предназначена для защиты солдата от снайперов путем акустической локализации выстрелов. Для этого на его шлеме устанавливаются мобильные антенны. Для "выявления снайперов" в районе операции до развертывания войск размещаются две акустические системы и видеокamеры дневного и ночного видения. Использование двух акустических решеток позволяет определить направление выстрела и возможное местоположение стрелка пу-

тем триангуляции акустических данных, камера дневного и ночного видения обеспечивает его изображение [Chang et al., 2006; Hengy et al., 2011; de Mel et al., 2012].

Локализация взрыва с использованием сети датчиков (BL): Ячеистая сеть недорогих акустических датчиков, выполняет трехмерную локализацию взрывов различной мощности с разницей во времени прибытия (TDOA) в нескольких различных средах. Система способна работать точно при наличии различных источников ошибок. После развертывания и активации каждый сенсорный узел самонастраивается в одноранговую, многокороостную, надежную WSN.

Защита периметра (PP): Широко используемые концепции защиты периметра с помощью зонных датчиков в ближайшем будущем будут заменены сенсорными системами с несколькими датчиками. Такого рода системы могут использовать дневные / ночные камеры, инфракрасные неохлаждаемые тепловизионные камеры, а также радары миллиметрового диапазона, обнаруживающие излучение, отраженное от цели. Помимо датчиков, наиболее важными элементами, влияющими на эффективность системы, являются интеллектуальный анализ данных и алгоритм объединения данных. Подобная система специальных WSN предназначенная для пограничного наблюдения рассмотрена в [Dulski et al., 2011; He et al., 2011].

Обнаружение химических, биологических и взрывоопасных паров с помощью датчиков с микроантилеверной матрицей (VDM). Существует технология чувствительной матрицы на основе микроантилевера (SSA) для измерения следовых концентраций взрывчатых веществ, токсичных химических веществ и сигнатур биологических агентов. Система-прототип использует различные сенсорные покрытия и возможность анализа электрических и тепловых свойств молекул пара на консолях [Adams et al., 2007].

Дистанционный химический датчик для платформ электронных беспилотных летательных аппаратов (RCS). Он разработан для установки на одноразовых беспилотных летательных аппаратах. Датчик позволяет обнаруживать химические пары в конфигурации обзора надиром с высоты 300 м при движении со скоростью 96 км /ч. Опасные химические вещества обнаруживаются и идентифицируются по их уникальным характеристикам инфракрасного поглощения. Чтобы уменьшить количество ложных срабатываний, возникающих в результате изменений сцены, в датчик были встроены 3 фотодиодных детектора с цветовой фильтрацией. Фотодиод детекторы просматривают ту же сцену, что и инфракрасные детекторы, и предоставляют дополнительную информацию о сцене, необходимую для различения изменений рельефа местности по химическим выбросам [Zehr et al., 2007].

Система оптических датчиков для непрерывного мониторинга ракетных контейнеров (МСМ). Мониторинг окружающей среды в контейнере ракеты значительно увеличивает срок ее активной службы, экономит миллионы долларов и сокращая количество необходимых ракет. Для этого требуется высокоскоростная система датчиков непрерывного мониторинга, которая собирает и хранит данные о воздействии окружающей среды и вибрации (до 100 г) в контейнерах с ракетами без опасности поражения электрическим током. Предложена оптическая сенсорная система, способная отслеживать удары и вибрацию в ракетных контейнерах в трех измерениях с высокой скоростью (5 кГц). Она может использоваться в системе мониторинга воздействия на окружающую среду для сбора и хранения данных о вибрации, ударах, температуре или повреждающих событиях в течение всего срока службы ракетного контейнера [Bukshpun et al., 2007].

Система распознавания звука акустической угрозы (АТЗ). Обнаружение, классификация и локализация угрожающих звуков могут быть эффективно использованы в асимметричной войне и против террористических угроз. Предлагаемая архитектура позволяет взаимодействовать между чувствительными узлами для совместного обнаружения сигнатур целей, уменьшения ложных тревог, классификации типов целей и оценки акустического местоположения источника. Его преимущества включают энергоэффективность, надежное обнаружение и классификацию, низкую задержку обнаружения и классификации, а также снижение ложных срабатываний [Deng et al., 2007].

Заключение

Для повышения возможностей применения WSNs в военных приложениях исследования и разработки должны быть направлены на создание: отечественных одно кристаллических процессоров, разработку алгоритмов идентификации нескольких одновременных событий; классификации объектов и событий в задачах обнаружения; миниатюризации и интеграции различных типов датчиков, повышение их надежности; форматов и стандартов для выходов датчиков и коммуникаций. Востребованными проблемами являются: разработка алгоритмов Sensor Data Mining на основе методов искусственного интеллекта и интеллектуального анализа данных, синтеза и генерации знаний на основе бортовой осведомленности и онтологий. Для повышения жизненного цикла WSNs требуется разработка новых источников питания, и энергоэффективных протоколов коммуникации.

Список литературы

- [Cannon et al., 2007] Cannon P.S. and Harding C.R. Future military wireless solutions. Ch. 8 // in *Wireless Communications: The Future*, Editor William Webb, John Wiley & Sons, 2007.
- [Winkler et al., 2008] M. Winkler, K.-D. Tuchs, Hughes K., and Barclay G. Theoretical and practical aspects of military wireless sensor networks // in *Journal of Telecommunications and Information Technology*. – 2/2008. – P. 37-45.
- [Lamont et al., 2011] Lamont L., Toulgoat M., Déziel M., and Patterson G. Tiered wireless sensor network architecture for military surveillance applications // *Proc. of the 5th International Conference on Sensor Technologies and Applications, SENSORCOMM 2011, Nice, France, August 21-27, 2011*.
- [Tafa et al., 2007] Tafa Z. and Milutinović V. Evaluating and improving the area coverage and detectability in the large-scale surveillance networks // *IEEE Communications Surveys & Tutorials* (submitted).
- [Виноградов и др., 2021] Виноградов Г.П., Конюхов И.А., Шепелев Г.А. Подход к проектированию программного обеспечения систем управления искусственными сущностями // Программные продукты и системы. – 2021. – № 1 (34).
- [Виноградов и др., 2020] Виноградов Г.П., Прохоров А.А., Шепелев Г.А. Паттерны в системах управления автономными робототехническими комплексами // Виноградов Г.П., Прохоров А.А., Шепелев Г.А. Паттерны в системах управления автономными системами // Мягкие измерения и вычисления. – 2020. – № 12.
- [Vinogradov, 2020] Gennady Vinogradov. Patterns in Intelligent Systems. Russian Advances in Fuzzy Systems and Soft Computing // Selected contributions to the 8-th International Conference on Fuzzy Systems, Soft Computing and Intelligent Technologies (FSSCIT-2020), June 29 – July 1, 2020, Smolensk, Russia. CEUR Workshop Proceedings. – 2020. – 2782, – P. 208-216.
- [Merrill et al., 2005] Merrill W.M. et al. Defense systems: self-healing land mines. Ch. 18 // in *Wireless Sensor Networks: A System Perspective*, Editors N. Bulusu and S. Jha, Artech House, 2005.
- [Naz et al., 2012] Naz P., Hengy S., Hamery P. Soldier detection using unattended acoustic and seismic sensors. SPIE. Orlando, USA, 2012. – 8389-28.
- [Rippin et al., 2012] B. Rippin. Pearls of wisdom: wireless networks of miniaturized unattended ground sensors. SPIE. Orlando, USA, 2012. – 8388-17.
- [Towle et al., 2007] Towle J.P., Johnson R., Vincent H.T. II. Low-cost acoustic sensors for littoral anti-submarine warfare (ASW). SPIE, Orlando, USA, 2007. – 6538-14.
- [Chang et al., 2006] Chang J. et al. Early attack reaction sensor (EARS): a man-wearable gunshot. SPIE, 2006. – 62011T.
- [de Mel et al., 2012]. de Mel G.R, Pham T., Bergamaschi F., Vasconcelos W., Norman T.J. Intent-based resource deployment in wireless sensor networks. SPIE, Orlando, USA, 2012. – 8389-29.
- [Hengy et al., 2011] Hengy S., Hamery P., De Mezzo S., Duffner P. “etworked localization of sniper shots using acoustics. SPIE, Orlando, USA, 2011. – 8046-01.
- [Dulski et al., 2011] Dulski R., Kastek M., Trzaskawka P., Szustakowski M., Zyczkowski M. Concept of data processing in multisensor system for perimeter protection. SPIE, Orlando, USA, 2011. – 8019-35.

- [He et al., 2011] He J., Norwood R.A., Fallahi M., Peyghambarian N. Smart border: ad-hoc wireless sensor networks for border surveillance. SPIE, Orlando, USA, 2011. – 8019-37.
- [Adams et al., 2007] Adams J.D., Whitten R., Rogers B.S. Chemical, biological, and explosive vapor detection with micro cantilever array sensors // SPIE Defense & Security Symposium, Orlando, USA, 2007.
- [Zehr et al., 2007] Zehr R.T., Holland S.K., Laufer G. A low-cost remote chemical sensor for E-UAV platforms // SPIE Defense & Security Symposium, Orlando, USA, 2007.
- [Bukshpun et al., 2007] Bukshpun L., Pradhan R.D., Tun N., Esterkin V., Tomczyk G. Novel optical sensor system for missile canisters continuous monitoring. SPIE 2007. – 6538-61.
- [Deng et al., 2007] Deng H., Xu H. Acoustic threatening sound recognition system. SPIE Defence Security Symposium, Orlando, USA, 2007.
- [Виноградов и др., 2022] Виноградов Г.П. Алгоритмы управления процессами в реагирующих сенсорных сетях для задач защиты объектов // Программные продукты и системы. – 2022. – Т. 35, № 2. – С. 229-339. – Doi: 10.15827/0236-235X.138.229-239/.
- [Виноградов и др., 2021] Виноградов Г.П., Емцев А.С., Федотов И.С. Беспроводные сенсорные сети в защищаемых зонах // Известия ЮФУ. Технические науки. – 2021. – № 1. – С. 19-30.

УДК 004.946:004.4'2

СЕМАНТИЧЕСКИЕ ТЕХНОЛОГИИ ДЛЯ РАЗРАБОТКИ ИММЕРСИВНЫХ ВИРТУАЛЬНЫХ СРЕД С БИОЛОГИЧЕСКОЙ ОБРАТНОЙ СВЯЗЬЮ*

В.В. Грибова (*gribova@dvo.ru*)

В.О. Стрекалёв (*strekalev.vo@dvo.ru*)

Институт автоматизи и процессов управления ДВО РАН,
Владивосток

В работе описана разработка и сопровождение виртуальных тренажеров с биологической обратной связью с использованием семантических технологий и онтологического представления информации. В основе предлагаемого решения лежит принцип четкого разделения между декларативными знаниями (знаниями предметной области) и процедурными (о методе решении задачи). Описаны принципы формирования каждого компонента - базы знаний и данных, решателя задач и пользовательского интерфейса.

Ключевые слова: Виртуальная реальность, биологическая обратная связь, онтологии, интеллектуальные системы, семантические технологии, базы знаний.

Введение

Разработка виртуальных тренажеров с биологической обратной связью является трудоемким процессом, но еще более сложным и трудоемким является сопровождение таких систем [Аладышев А. В. Субботин Е.А.]. Поэтому исследование методов, средств, технологий разработки и сопровождения остается одной из актуальных задач [Смолин А.А., Селиванов В.В., Селиванова Л.Н., Сооган С.Г., Не В.]. Процесс разработки компьютерного тренажера в настоящее время все более связан с построением базы знаний, базирующейся на семантической сети, которая позволяет обеспечить необходимую скорость и качество информационного моделирования технологического процесса [Коцюба И.Ю.].

Авторами предлагается создавать виртуальный тренажер (ВТ) с биологической обратной связью (БОС) по его модели, для формирования которой используется онтологический подход и семантическое представление ин-

* Работа выполнена при частичной финансовой поддержке фонда содействия инновациям, договор № 269ГУЦЭС8-Д3/56658, и РФФИ, проект № 20-07-00670.

формации. Модель состоит из набора связанных компонентов, каждый из которых формируется под управлением соответствующей онтологии. Онтологии, базы данных и знаний представлены семантическими сетями. Такой подход позволяет специалистам, не знакомым с языками программирования и технологиями разработки программных систем, описать ВТ с БОС в терминах онтологии с помощью специализированных редакторов, ориентированных на их специализацию. Применимость и удобство онтологического подхода для создания тренажеров с включением специалистов различного профиля продемонстрировано в работах [Грибова В.В., Стрекалев В.О.]. Средство разработки, воспроизведения и сопровождения ВТ с БОС включает информационные, программные ресурсы, а также пользовательский интерфейс.

Целью данной работы является описание использования онтологического подхода и семантического представления информации для формирования информационных и программных ресурсов виртуального тренажера с биологической обратной связью.

1. Информационные ресурсы

К информационным ресурсам предлагаемого решения относятся следующие виды информации: онтологии, модель ВТ с БОС, база знаний и базы данных. Все информационные ресурсы представлены семантически сетями, а именно иерархическими однородными бинарными ориентированными графами (орграфами). Структура взаимодействия между компонентами показана на рис. 1.

Рис. 1. Структура взаимодействия между компонентами

Модель ВТ с БОС состоит из множества компонентов, каждый из которых формируется на основе соответствующей онтологии. Онтология задает структуру компонента, терминологию, правила формирования соответствующего компонента модели, ограничения целостности:

- онтология виртуальной среды предназначена для описания множества сцен, объектов с набором параметров и функций, необходимых для управления виртуальным окружением;
- онтология исследований включает систему понятий, правила и ограничения для формирования исследования (либо модели тренинга) и создания индивидуального сценария работы, с учетом параметров пользователя;
- онтология знаний о состояниях пользователя предназначена для описания состояний, которые могут быть (диагностироваться) в процессе взаимодействия пользователя с тренажером; каждое состояние определяется как набор статических и динамических параметров (статическими параметрами могут выступать пол, возраст, сопутствующие заболевания и др., динамические параметры – это параметры, получаемые с приборов, например, пульс, давление и др.);
- онтология карты пользователя, состоящая из записей данных сеанса и результатов проведенных исследований;
- онтология оборудования, которая включает описание различного оборудования и способы работы с ним.
- Онтологии и модели, формируемые на их основе, имеют семантическое представление. На рис. 2,а,б) приведен фрагмент скриншота онтологии виртуальной среды и фрагмент модели, сформированный на ее основе.

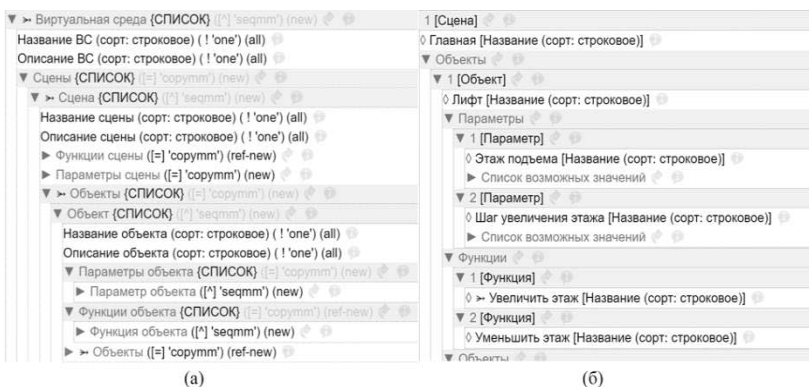


Рис. 2. Онтология виртуальной среды (а) и фрагмент модели (б)

2. Программные ресурсы

Система создания, сопровождения и воспроизведения виртуальных тренажеров с биологической обратной связью представляет собой решение, в котором используется набор программно-аппаратных средств, позволяющих осуществить полный жизненный цикл виртуального тренажера. Стоит отметить, что для разработки ВТ с БОС используются как инструменты, предложенные в данной работе, так и внешние инструменты, такие как интерактивное средство создания и редактирования виртуальных объектов (Blender) и средство для создания, изменения и сборки виртуальной среды, которое позволяет сформировать виртуальные сцены в инструментальном средстве разработки (Unity3D) и в дальнейшем интегрировать наборы компонентов, сгенерированные с использованием предлагаемого решения. Рассматривая программные ресурсы, можно выделить следующие компоненты:

Подсистема создания виртуальных тренажеров. С помощью данной подсистемы производится информационное наполнение разрабатываемого тренажера, в котором сосредоточены ключевые процессы, связанные с описанием и подготовкой материалов для последующего создания виртуальной среды и тренажера на ее основе. Для реализации возможности создания виртуальных тренажеров и формирования информационного наполнения используется платформа для разработки интернет-сервисов – программно-информационный интернет-комплекс IACaaS (Intelligent Application, Control and Platform as a Service), предоставляющий контролируемый доступ и единую систему администрирования для создания и использования интеллектуальных сервисов и их компонентов, представленных семантическими сетями, поддержку функционирования агентов (через передачу и обработку сообщений, запуск методов).

Подсистема воспроизведения виртуальных тренажеров. С помощью подсистемы воспроизведения виртуальных тренажеров происходит запуск и функционирование разработанных тренажеров с возможностью погружения в виртуальную реальность. Данное средство позволяет выбрать разработанный тренажер, заполнить информацию о пользователе и запустить сеанс. Средство запуска решает такие задачи, как подготовка и инициализация сеанса, синхронизация виртуальной среды с оборудованием ВТ с БОС.

Подсистема мониторинга и управления. С помощью средства мониторинга решаются такие задачи, как демонстрация текущего состояния пользователя, погруженного в сеанс на виртуальном тренажере; отображение данных, получаемых с оборудования; синхронизация действий пользователя с его физиологическими параметрами (частота пульса, тем-

пература тела итд); взаимодействие с базой данных. Средство управления реализует поддержку внешнего механизма управления ВТ, а именно, позволяет в реальном времени внести корректировки в сценарий, отключить компоненты и контролировать процесс воспроизведения ВТ.

Генератор программных компонентов. Используя генерацию программных компонентов виртуального тренажера, можно создавать различные тренажеры с изменяемыми характеристиками. На вход генератора поступает декларативная модель, на основе которой производится формирования виртуальной сцены: установка объектов, привязки событий, установки начальных значений параметрам сцены. Модель переводится в структурированный пакет, который в дальнейшем использует интерпретатор и производит настройку объектов на основе описанных характеристик и доступных функций.

Формирование виртуального тренажера состоит из трех шагов:

1. Формирование всех объектов сцены, их инициализация, установка параметров уровня представления, логических атрибутов и установка начальных состояний.
2. Инициализация действий, событий, установка связей между событиями и действиями.
3. Инициализация связей между параметрами. Инициализация ссылок на изменение характеристик объектов в соответствии с параметрами пользователя.

3. Пользовательский интерфейс

В предлагаемом решении при разработке пользовательского интерфейса для удобства взаимодействия между компонентами системы были спроектированы и реализованы интерфейсы с учетом следующих особенности для каждого типа пользователя:

Интерфейс разработчика. Рабочее пространство разработчика реализовано на платформе IASaaS и представлено в виде web-интерфейса, позволяющего осуществить взаимодействие разработчика с системой через браузер. Платформа IASaaS основана на технологии облачных вычислений и обеспечивает удаленный доступ конечным пользователям к интеллектуальным системам, а разработчикам и управляющим – к средствам создания интеллектуальных систем и управления ими [Грибова В.В., Клещев А.С., Москаленко Ф.М., Тимченко В.А., Федорищев Л.А., Шалфеева Е.А.]. На рис. 3 показан личный кабинет разработчика.

Мой Фонд	
Корзина	
Загрузки	
Онтологии	
Базы знаний	
Базы	
EX	
check	
Экспорт	

EX (14) ↑		сортировка ▾
tm		2021-10-27
Онтология исследований		2022-04-04
База исследований		2022-05-15
Онтология карты пользователя		2022-04-04
Карта		2022-05-15
Шаблон признака		2021-12-08
Онтология терминов		2021-06-08
Онтология значений		2021-05-31
База терминов		2021-06-09
Онтология виртуальной среды		2022-04-04
База виртуальных сред		2022-04-04
Онтология оборудования		2021-10-06
База оборудования		2021-10-06
Условия		2022-04-04

Рис. 3. Интерфейс разработчика

Интерфейс оператора. Данный интерфейс представляет собой web-приложение, с помощью которого производится демонстрация текущего состояния пользователя, погруженного в сеанс на виртуальном тренажере, оператор может: просматривать данные, получаемые с оборудования, увидеть текущий этап выполнения сценария с учетом действий пользователем. На рис. 4 показан интерфейс оператора, представленный визуализацией данных, получаемых с оборудования.

Рис. 4. Интерфейс оператора

Интерфейс пользователя. Данный интерфейс основан на использовании технических средств, при котором изменения состояния виртуальных объектов происходит при взаимодействии с контроллерами, которые за-

крепляются на руках или на теле, создается ощущение непосредственного прикосновения реального тела с виртуальным объектом, а также пользователю демонстрируется трехмерное пространство при помощи специализированного шлема, состоящего из экрана и линз, формирующих объемное изображение. Учитывая технические особенности, это позволяет создавать комбинированные осязаемые интерфейсы, которые формируют у пользователя новый, уникальный опыт взаимодействия с виртуальным тренажером.

Заключение

В работе описана разработка и сопровождение виртуальных тренажеров с использованием семантических технологий и онтологического представления информации. В основе предлагаемого решения лежит принцип четкого разделения между декларативными знаниями (знаниями предметной области) и процедурными знаниями (о методе решения задачи). Это позволяет специалистам, не знакомым с языками программирования и технологиями разработки программных систем, описать виртуальный тренажер в терминах онтологии с помощью специализированных интерфейсов, ориентированных на их специализацию.

Все информационные ресурсы имеют единый унифицированный формат представления – семантическую сеть. Это обеспечивает возможность доступа ко всем типам ресурсов (как данным, так и знаниям) через оболочку, представляющую набор программных интерфейсов, отображающих необходимую предметную область, что значительно упрощает к ним доступ, поскольку разработчику не надо знать детали внутренней организации информации и программировать доступ к ней. Программные ресурсы представлены в виде совокупности подсистем, с набором инструментов, включающих необходимые программные компоненты и расширяемые модули. Поддержка процесса формирования и сопровождения виртуального тренажера обеспечивается генератором программных компонентов, который на основе модели формирует необходимые модули, интегрируемые в инструментальную среду разработки. Пользовательский интерфейс представлен с учетом особенностей каждого типа пользователя (разработчик, оператор, конечный пользователь) и организует удобство взаимодействия между элементами системы в зависимости от решаемой задачи. В целом система создания, сопровождения и воспроизведения виртуальных тренажеров с биологической обратной связью является более эффективной формой работы с виртуальными тренажерами, позволяющей обеспечить погружение конечного пользователя в виртуальную среду, с учетом его особенностей, а разработчикам и оператору – к средствам создания и управления виртуальным тренажером и его компонентам.

Список литературы

- [Аладышев А.В. Субботин Е.А.] Функциональное биоуправление с обратной связью – перспективная информационная технология в медицине // Современные наукоемкие технологии. – 2005. – № 3. – С. 86-87.
- [Смолин А.А.] Системы виртуальной, дополненной и смешанной реальности: учеб. пособие // СПб.: Изд-во Ун-та ИТМО, 2018. – 59 с.
- [Селиванов В.В., Селиванова Л.Н.] Виртуальная реальность как метод и средство обучения [Текст] // ОТО. – 2014. – № 3. – С. 378-391
- [Coogan C.G., He B.] Brain-Computer Interface Control in a Virtual Reality Environment and Applications for the Internet of Things // in IEEE Access. – 2018. – Vol. 6. – P. 10840-10849. – Doi: 10.1109/ACCESS.2018.2809453.
- [Грибова В.В., Стрекалев В.О.] Инструментальный комплекс для иммерсивных виртуальных тренажеров с биологической обратной связью // Вестник компьютерных и информационных технологий. – 2020. – № 8. – С. 19-28. – Doi: 10.14489/vkit.2020.08. pp.019-028.
- [Грибова В.В., Стрекалёв В.О.] Комплекс онтологий для виртуальных тренажеров с биологической обратной связью // Онтология проектирования. – 2022. – Т. 12, № 2 (44). – С. 172-185. – Doi: 10.18287/2223-9537-2022-12-2-172-185.
- [Коцюба И. Ю.] Коцюба И.Ю. Методы и алгоритмы поддержки разработки нечетких семантических моделей для компьютерных тренажеров: дисс. ... канд. техн. наук: 05.13.06; [Место защиты: ФГАОУ ВО «Национальный исследовательский университет ИТМО»], 2018. – 190 с.
- [Грибова В.В., Клещев А.С., Москаленко Ф.М., Тимченко В.А., Федорищев Л.А., Шалфеева Е.А.] Облачная платформа IASaaS для разработки оболочек интеллектуальных сервисов: состояние и перспективы развития // Программные продукты и системы. – 2018. – № 3.

УДК 004.89:[612.821:343.98]

РАЗВИТИЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ПОДДЕРЖКИ НАУЧНЫХ ИССЛЕДОВАНИЙ В КРИМИНАЛИСТИКЕ

С.М. Гусакова (*svem45@yandex.ru*)
Федеральный исследовательский центр «Информатика
и управление» РАН, Москва

Н.В. Огорельцева (*nat@gmail.com*)
АО "Тинькофф Банк"

В докладе излагается расширение функциональности интеллектуальной ДСМ-системы для психолого-криминалистических исследований. Приводятся результаты проведенных экспериментов.

Ключевые слова: интеллектуальная ДСМ-система, психологические характеристики, особенности подписи, дополнительные параметры, неатомистический вариант ДСМ-метода, операция сходства, двухуровневая структура, темперамент.

Введение

В настоящее время приходит осознание возможности использования для решения задач в области криминалистики методов искусственного интеллекта. В [Ермоленко, 2019] нейронная сеть используется для решения идентификационной задачи. В [Pratiwi, 2017] описана программа, которая на основе четырех выделенных признаков почерка с помощью графологического анализа устанавливает тип личности, в [Maliki, 2020] предложена система психологического анализа личности на основе графологического анализа подписей с использованием машинного обучения. Методы искусственного интеллекта используются здесь на уровне автоматического выделения признаков и использования графологических методик.

Следует обратить внимание, что практически во всех современных работах, касающихся исследований в этой области, речь идет о выявлении психологических характеристик по почерку, и, по-видимому, именно такая постановка вопроса приводит к тому, что в психолого-почерковедческих исследованиях активно используются методы графологии. При этом отмечается, что почерковеды критикуют графологический подход, сомневаясь в его научной обоснованности [Гукасян, 2019].

В [Гросс и др., 2020] и [Гусакова и др., 2021] описана интеллектуальная система, нацеленная на проведение психолого-криминалистических исследований с целью выявления влияния психологических характеристик на особенности подписи без использования графологических методик. Эта система основана на ДСМ-методе автоматизированной поддержки исследований, одном из методов интеллектуального анализа данных, позволяющем извлекать новое знание из данных, содержащихся в базе фактов с учетом модели предметной области [Финн, 2013].

Система состоит из двух подсистем – «Подпись» и «Психология». Подсистема «Подпись» работает с данными, содержащимися в образцах подлинных подписей респондентов и подделок этих подписей, выполненных другими лицами, и решает задачи идентификации подписи и нахождения в автоматизированном режиме малоинформативных признаков. Все образцы представлены набором общих и частных признаков подписи.

Подсистема «Психология» предназначена для решения задачи выявления влияния психологических характеристик человека на особенности выполнения им подписи. Психологические характеристики представлены значениями шкал психологических опросников, полученных в результате заполнения респондентами этих опросников и их автоматической обработки.

Существенными моментами построения описываемой подсистемы являются наличие помимо основного психологического опросника нескольких дополнительных и использование неатомистического варианта ДСМ-метода [Гусакова, 2021]. Необходимость привлечения нескольких опросников объясняется отсутствием в психологии и криминалистике точных сведений о том, какие именно психофизиологические особенности человека проявляются в тех или иных признаках его подписи, при том что принципиально такое влияние не вызывает сомнений [Гайворонская, 2019, Чернов, 2011].

Выбор между атомистическим и неатомистическим вариантами ДСМ-метода определяется содержанием решаемой задачи, представлением данных и их информативностью. Принципиальное различие атомистического и неатомистического методов определяется структурой базы фактов (БФ). База фактов в ДСМ-методе содержит множества объектов и эффектов. В атомистическом варианте база фактов реализует два отношения: «объект X проявляет набор эффектов Y» и «объект X не проявляет набор эффектов Y», которые делят ее на положительную и отрицательную части. Эффекты из набора Y независимы.

В результате применения стратегии ДСМ-метода к такой базе фактов находятся причины проявления объектами эффектов (гипотезы I-го рода) и доопределяются примеры, про которые неизвестно, проявляют они эффекты или нет (гипотезы II-го рода).

Есть задачи, в которых все примеры базы фактов таковы, что каждый объект обладает соответствующим эффектом. Нужно выявить, какая часть объекта влияет на проявление этого эффекта. Для таких задач применяется неатомистический вариант ДСМ-метода. Эффект рассматривается как единое целое, а база фактов реализует одно отношение «объект X проявляет эффект Y». На положительную и отрицательную части базу фактов делит внешний фактор, относящийся к примерам. В задачах, требующих использования неатомистического варианта ДСМ-метода, первоочередной интерес для исследователя представляют гипотезы I-го рода. Наличие внешнего разделительного фактора позволяет оценить его влияние на зависимости между объектами и эффектами. Неатомистический вариант применяется для задач, в которых объект описывается разноплановыми характеристиками и требуется выявить зависимость между содержанием этих описаний. Примерами таких задач являются задача качественного формализованного анализа социологических данных и задача выявления влияния психологических характеристик человека на особенности его подписи.

Алгоритм нахождения потенциальных гипотез [Гусакова и др., 2016] и его программная реализация позволили провести эксперименты, выявившие некоторые зависимости между характеристиками темперамента и особенностями подписей. Эти эксперименты с одной стороны подтвердили работоспособность системы, наличие влияния психологических характеристик на особенности подписи, с другой стороны указали на возможность проведения дополнительных исследований.

ДСМ-метод, содержащий целый набор стратегий [Финн, 2014], позволяет в рамках одной компьютерной системы решать разные задачи в предметной области. Это было использовано для расширения функциональности созданной подсистемы «Психология» с целью извлечения нового знания и решения новых задач. Для этого были привлечены новые данные и расширена модель предметной области.

В докладе описано это расширение и представлены результаты проведенных с его помощью экспериментов.

1. Расширенная функциональность и новые задачи

Подсистемы «Подпись» и «Психология» связаны через респондентов. В подсистеме «Психология» использовалось описание подлинных подписей респондентов для нахождения эмпирических зависимостей вида «Набор психологических характеристик С влияет на проявление в подписях множества признаков Q». Психологические характеристики представлены набором значений шкал опросников. Среди выбранных опросников один объявляется главным, остальные являются дополнительными параметра-

ми. В подсистеме «Психология» главным считается опросник структуры темперамента (ОСТ), дополнительные параметры – опросники черт характера (ОЧХ), самочувствие, активность, настроение (САН) и опросник уровня агрессивности Басса-Перри (БП).

Для решения новых задач были привлечены дополнительные данные:

- помимо описания подлинных подписей респондентов были использованы описания поддельных подписей, выполненных от лица респондентов иными лицами (ранее поддельные подписи использовались только в подсистеме «Подпись»);
- каждый частный признак каждой подписи охарактеризован с точки зрения его устойчивости или вариативности в различных образцах;
- психологические характеристики расширены описанием типа темперамента каждого респондента, вычисляемого по значениям шкал опросника структуры темперамента;
- для лиц, подделывавших подписи, были использованы их психологические характеристики.

Это позволило решать следующие новые задачи:

- влияние структуры темперамента (опросник ОСТ) с привлечением черт характера (опросник ОЧХ) на устойчивость признаков подписи;
- нахождение зависимости трудно подделываемых признаков от темперамента;
- определение влияния фактора, разделяющего БД на положительную и отрицательную части, на характер получаемых зависимостей;
- влияние сходства психологических характеристик респондента и лица, выполнившего подпись от его имени, на качество подделки.

Для решения этих задач понадобилось внести изменения в модель предметной области.

Язык представления данных был расширен новыми признаками. Для каждого респондента к описанию его психологических характеристик структуры темперамента (опросник ОСТ) была добавлена пара признаков – предметный и коммуникативный темперамент. Из восьми шкал ОСТ четыре характеризуют предметный темперамент и четыре – коммуникативный. Темперамент определяется по одинаковому значению соответствующих шкал. В психологии различают четыре темперамента – холерики, сангвиники, меланхолики и флегматики. Также надо учитывать, что часто темперамент не определяется точно, а является смешанным [Русалов, 2012]. Высокое значение всех шкал задает холерический темперамент. (Исключение допускается для шкалы *Пластичность*, которая может принимать среднее значение), а среднее значение – сангвинический. Если, например, значения всех предметных шкал – высокое, а коммуникативных – среднее, то предметный темперамент

холерический, а коммуникативный – сангвинический. Таким образом психологические характеристики опросника структуры темперамента (объект базы фактов) описываются в виде:

$$X = \{x_1, \dots, x_8; (t_s, t_c)\},$$

где x_i – значения шкал ОСТ, t_s , и t_c – значения предметного и коммуникативного темпераментов. Пара (t_s, t_c) может принимать одно из 25-ти возможных значений.

К описанию каждого частного признака подписи добавляется признак устойчивости, который имеет два значения – *устойчивый*, если значение признака одинаково не менее чем в девяти образцах из десяти, и *вариативный* в противном случае.

К каждому респонденту с его психологическими характеристиками помимо описаний подлинных подписей добавляются описания поддельных.

Описания подписей (эффект) теперь имеют вид:

$$Y = Y_c, Y_{pr}; Y_c = \{y_1, \dots, y_{14}\}, Y_{pr} = \{P: p_i, s_i\},$$

где Y_c, Y_{pr} – общие и частные признаки соответственно, y_j – значение одного из 14-ти общих признаков, P – имя частного признака, p_i – его значение, s_i – значение признака *устойчивость*. Иерархическая структура частного признака подробно описана в [Гросс и др., 2021].

Пример базы фактов в расширенной ДСМ-системе имеет вид:

$$X \Rightarrow_1 (Y_c, Y_{pr})_a, (Y_c, Y_{pr})_f,$$

здесь $(Y_c, Y_{pr})_a$ – описание подлинных, а $(Y_c, Y_{pr})_f$ – описание поддельных подписей, \Rightarrow_1 – отношение «объект проявляет эффект».

Поскольку в ДСМ-системах для обнаружения нового знания применяются правдоподобные выводы, следствия которых не содержатся явно в посылках, а извлекаются с помощью механизмов обнаружения сходства, зависящего от содержания задачи и языка представления данных, для новых задач потребовалось определить новые операции сходства.

Сходство по темпераменту:

$$X_n \Pi_1 X_m = \begin{cases} X_n, & \text{если } X_n = X_m; \\ \emptyset, & \text{если } X_n \neq X_m. \end{cases}$$

Сходство по предметному или коммуникативному темпераменту:

$$\hat{X} \Pi \tilde{X} = \begin{cases} ((\hat{t}_s, \hat{t}_c), \text{если } (\hat{t}_s = \tilde{t}_s) \wedge (\hat{t}_c = \tilde{t}_c); \\ (\hat{t}_s, \emptyset) \vee (\emptyset, \hat{t}_c), \\ \text{если } ((\hat{t}_s = \tilde{t}_s) \wedge (\hat{t}_c \neq \tilde{t}_c)) \vee (\hat{t}_s \neq \tilde{t}_s) \wedge (\hat{t}_c = \tilde{t}_c); \\ (\emptyset, \emptyset), \text{если } (\hat{t}_s \neq \tilde{t}_s) \wedge (\hat{t}_c \neq \tilde{t}_c). \end{cases}$$

При определении сходства для задачи выявления зависимости между темпераментом и трудно подделываемыми признаками подписи необходимо привлечь данные из поддельных подписей. Эта операция сходства определяется на общих признаках подписи. Она должна отражать тот факт, что по подписям сходны примеры, имеющие одинаковые признаки, значения которых в подлинных подписях не совпадают с их значениями в поддельных. При этом сами значения этих признаков у разных респондентов могут не совпадать.

Содержательно это может быть выражено так:

$$Y_n \text{ П } Y_m = \begin{cases} j, & \text{если } ((y_j^n)_a \neq (y_j^n)_f) \wedge ((y_j^m)_a \neq (y_j^m)_f); \\ \emptyset, & \text{если } ((y_j^n)_a = (y_j^n)_f) \vee ((y_j^m)_a = (y_j^m)_f). \end{cases}$$

здесь j – номер общего признака.

Однако в таком виде операцию сходства определить нельзя, так как она не удовлетворяет свойству идемпотентности: $Y \text{ П } Y = Y$. Чтобы обойти эту проблему, нужно изменить описание подписи в части, относящейся к общим признакам:

$$Y_c = \{j_1, \dots, j_{14}\},$$

где на i -ом месте стоит номер общего признака j_i , если $(y_j)_a = (y_j)_f$ или 0, если $(y_j)_a \neq (y_j)_f$, т.е. содержательную часть операции сходства перенести в язык представления данных. Тогда операция сходства определяется как пересечение Y_c и Z_c .

Чтобы не менять базу фактов в связи с изменением языка представления данных, при вычислении результатов новых операций сходства учет этих изменений закладывается в алгоритм и реализуется программно.

2. Алгоритмы, средства разработки и интерфейс

Для расширения функциональности интеллектуальной системы был реализован ряд новых алгоритмов:

- определение темперамента респондентов;
- определение устойчивости частных признаков;
- нахождение трудно подделываемых признаков в зависимости от темперамента;
- нахождение сходств поддельных подписей для сравнения их с подлинными.

На архитектурном уровне реализация системы имеет двухуровневую структуру, состоящую из:

- базы данных на удаленном сервере для хранения информации о респондентах, заполненных ими опросниках и описанных подписях;

- интерфейса и программной логики, которая производит необходимые вычисления и собирает пользовательские представления в виде html-страниц.

Так как система использует некоторые персональные данные, доступ к ней можно получить только с помощью регистрации и одобрения администратором необходимых уровней доступа.

В системе предусмотрено три режима работы для пользователя в зависимости от уровня доступа:

- «респондент»: имеет доступ только к страницам заполнения опросника и просмотру их результатов;
- «эксперт»: имеет доступ к страницам «респондента» и разделу «Исследования», где происходят вычисления для исследовательских задач;
- «администратор»: имеет доступ как у «эксперта» и к административным страницам системы, с помощью которых можно управлять данными в базе, а также выдачей доступов зарегистрированным пользователям.

Система реализована с помощью следующих средств разработки:

- веб-фреймворк Django на языке Python для реализации клиент-серверного приложения.
- СУБД MySQL для хранения базы фактов;
- инструменты для корректной работы приложения на сервере: прокси-сервер Nginx и WSGI-сервер Gunicorn.

Для решения новых задач были добавлены инструменты для кэширования (Redis) и Python-библиотека Pandas для обработки результатов вычислений.

К интерфейсу системы, созданному ранее, помимо страницы, позволяющей выбрать решаемую задачу, страницы, показывающей содержание базы фактов и страницы, представляющей классификацию гипотез, добавлена страница классификации гипотез с дополнительными параметрами. На этой странице можно выбрать параметры подбора гипотез – по опросникам, по минимальному количеству респондентов, породивших гипотезы, по фактору разделения на (+) и (-)-примеры. Можно посмотреть также гипотезы, полученные для решения задач с использованием поддельных подписей.

Для удобства анализа данных была реализована возможность выгрузки результатов в Excel.

3. Результаты работы интеллектуальной системы

При проведении исследований в расширенной системе были получены следующие результаты.

При нахождении гипотез с дополнительным параметром по опроснику черт характера (ОЧХ) и разделению на положительные и отрицательные примеры по полу у женщин была найдена следующая гипотеза: *стремление к напряженному физическому и умственному труду, быстрый переход с одного вида деятельности на другой, стремление к разнообразию предметной деятельности, моторно-двигательная быстрота* (высокие значения предметных шкал опросника ОСТ) и эмоциональная подавленность и бесстрашие (низкие значения шкал «Экзальтированность» и «Тревожность» опросника черт характера ОЧХ), дают значение частных признаков подписи *Протяженность движений по вертикали* и *Протяженность движений по горизонтали* – *увеличена*. Причем это значение устойчиво. При таких же значениях предметных шкал ОСТ, но высоком уровне экзальтированности и тревожности значения указанных признаков подписи вариативны. У респондентов с сочетанием средних, высоких и низких значений шкал ОСТ со средними значениями по ОЧХ значения признаков, связанных с протяженностью движений, тоже вариативны.

У мужчин наблюдается такая же картина, но при высоких значениях предметных шкал ОСТ и низкой экзальтированности и тревожности значения признаков протяженности различны для разных букв, при этом каждое значение устойчиво.

Из этого эксперимента можно сделать следующие выводы. На устойчивость значений признаков *Протяженность движений по вертикали* и *Протяженность движений по горизонтали* влияют психологические черты, определяемые предметными шкалами опросника структуры темперамента и шкалами опросника черт характера, связанными с экзальтированностью и тревожностью. Причем только высокие значения шкал ОСТ в сочетании с низкими значениями шкал ОЧХ определяют устойчивость значений признаков подписи, характеризующих протяженность движений по вертикали и/или горизонтали. У мужчин и женщин при сохранении устойчивости эта зависимость имеет не одинаковый вид в части значений признаков. Это значит, что пол оказывает влияние на искомые зависимости.

Еще один вид экспериментов проводился с целью определения признаков подписи, которые трудно подделать, и выявления зависимости этих признаков от типа темперамента.

Как было указано выше, для проведения указанных исследований была определена новая операция сходства на примерах базы фактов. Содержательно эта операция отражает тот факт, что сходны респонденты одинакового темперамента и имеющие одинаковые признаки, значения которых в подлинных подписях не совпадают с их значениями в поддельных. При этом сами значения этих признаков у разных респондентов могут не совпадать.

Результат экспериментов показал, что у респондентов с холерическим типом обоих видов темперамента в поддельных подписях наблюдается изменение значения признака *направление линии подписи*.

У респондентов с сангвиническим типом темпераментов обоих видов имеет место изменение значений признака *форма основания подписи*. У респондента с предметным темпераментом по типу сангвиника, а коммуникативным по типу холерика в поддельной подписи изменено значение признака *направление линии подписи*, а значение признака *форма основания подписи* не изменено.

При анализе полученных результатов надо обратить внимание на тот факт, что значения признака *направление линии подписи* в подлинных подписях холериков имеет сложную структуру – *от горизонтального до поднимающегося, горизонтальное-поднимающееся-опускающееся*, в то время как значения признака *форма основания подписи* более выровнено. У сангвиников наоборот – *форма основания подписи* имеет сложные значения – *ступенчатая-прямолинейная-извилистая* или *дугобразная-извилистая*, а *направление линии подписи* более выровнено. Это затрудняет подделку соответствующих признаков.

Пример респондента сангвинического типа темперамента в предметной области и холерического в коммуникативной, у которого в поддельной подписи имеет место изменение значения признака *направление линии подписи* по холерическому типу, позволяет предположить, что коммуникативный темперамент больше влияет на сложность изображения признака, чем предметный. Однако одного примера явно недостаточно, чтобы делать определенные выводы.

Следует отметить, что опросник ОЧХ не дал результатов по сходству указанных респондентов, из чего можно сделать вывод, что выявляемые им характеристики не влияют на сложность подделки тех или иных признаков подписи.

Был также проведен эксперимент, позволивший предположить, что наличие общих психологических характеристик у респондентов и других лиц, выполнивших подписи от их имени, могут облегчить воспроизведение некоторых подделываемых признаков подписи.

Поддельный образец, выполненный человеком, не имеющим общих психологических характеристик с лицом, чью подпись он подделывал при идентификации, был определен как *вероятно поддельный*. Этим же человеком была подделана подпись другого респондента, с которым у него одинаково высокие значения шкал ОСТ «Темп» и «Социальный темп». Вывод по образцу подписи, представленному на идентификацию, о его поддельности сделать не удалось. Это значит, что во втором случае подделка выполнена более качественно, чем в первом.

Заключение

Созданная интеллектуальная ДСМ-система представляет из себя инструмент, дающий возможность исследователю создавать условия для решения различных исследовательских задач в области психологии и криминалистики. Такая возможность обеспечивается наличием множества стратегий и вариантов ДСМ-метода, и использованием дополнительных параметров. Использование неатомистического варианта ДСМ-метода позволяет также изучать влияние на получаемые эмпирические зависимости различных внешних факторов, таких, например, как пол респондентов.

Проведенные эксперименты показали дееспособность системы. Одним из результатов является установление факта, что основное влияние на особенности подписи оказывают психологические черты, определяемые опросником структуры темперамента. В некоторых случаях влияют черты характера. Влияние опросников САН и БП, эксперимент с привлечением которых проводился ранее, не выявлено, поэтому они должны быть заменены.

Однако найденные зависимости являются предварительными и не могут претендовать на статус эмпирических закономерностей. Полученные результаты должны быть проверены на устойчивость при последовательном расширении базы фактов и проведении ДСМ-исследования [Финн и др., 2018].

Большая информативность данных, содержащихся в базе фактов, дает различные типы зависимостей, что требует квалифицированного анализа результатов специалистами в предметной области.

Список литературы

- [Гайворонская, 2019] Гайворонская А.А. Почерк как одна из имманентных характеристик индивидуального сознания // Актуальные вопросы судебно-психологической экспертизы и комплексной экспертизы с участием психолога. Перспективы научного и прикладного исследования почерка: Сборник материалов III международной научно-практической конференции – Калуга: Изд-во КГУ им. К.Э. Циолковского, 2019.
- [Гукасян, 2019] Гукасян М.С. История развития графологии: судебно-почерковедческая экспертиза // Актуальные вопросы судебно-психологической экспертизы и комплексной экспертизы с участием психолога. Перспективы научного и прикладного исследования почерка. Сборник материалов III международной научно-практической конференции. – Калуга: Изд-во КГУ им. К.Э. Циолковского, 2019.
- [Гросс и др., 2020] Гросс Е.Р., Гусакова С.М., Огорельцева Н.В., Охлупина А.Н. ДСМ-система психолого-почерковедческих исследований подписи // Научно-техническая информация. Сер. 2. – 2020. – № 10.

- [Гусакова и др., 2021] Гусакова С.М., Огорельцева Н.В. Методы интеллектуального анализа данных в криминалистике: особенности применения и компьютерной реализации // XIX Национальная конференция по искусственному интеллекту с международным участием КИИ-2021 (11–16 октября 2021г., г. Таганрог, Россия). Труды конференции. – Таганрог: Изд-во ЮФУ, 2021.
- [Гусакова, 2021] Гусакова С.М. Интерпретация гипотез в задачах с дополнительными параметрами // Научно-техническая информация. Сер. 2. – 2021. – № 6.
- [Гусакова и др., 2016] Гусакова С.М., Михеенкова М.А. Интеллектуальный анализ данных как инструмент формирования структуры социума // Научно-техническая информация. Сер. 2. – 2016. – № 8.
- [Ермоленко, 2019] Ермоленко А.В. Аспекты идентификации автора почерка с помощью нечёткой логики и нейросетей. // Актуальные вопросы судебно-психологической экспертизы и комплексной экспертизы с участием психолога. Перспективы научного и прикладного исследования почерка: Сборник материалов III международной научно-практической конференции. – Калуга: Изд-во КГУ им. К.Э. Циолковского, 2019.
- [Maliki, 2020] Maliki I., Sidik M.A. Personality Prediction System Based on Signatures Using Machine Learning. // IOP Conference Series: Materials Science and Engineering. Vol. 879. – London: IOP, 2020.
- [Pratiwi et al, 2017] Pratiwi D., Santoso G. B., Saputri F.H. The application of graphology and enneagram techniques in determining personality type based on handwriting features // Jurnal Ilmu Komputer dan Informasi (Journal of Computer Science and Information). – 2017. – No. 10 (1).
- [Русалов, 2012] Русалов В.М. Темперамент в структуре индивидуальности человека. – М.: Ин-т психологии РАН. 2012 г.
- [Финн, 2013] Финн В.К. Эпистемологические основания ДСМ-метода автоматического порождения гипотез // Научно-техническая информация. Сер. 2. – 2013. – № 9 (Ч. I). – № 12 (Ч. II).
- [Финн, 2014] Финн В.К. Дистрибутивные решетки индуктивных ДСМ-процедур // Научно-техническая информация. Сер. 2. – 2014. – № 11.
- [Финн и др., 2018] Финн В.К., Шестерникова О.П. Эвристика обнаружения эмпирических закономерностей посредством ДСМ-рассуждений // Научно-техническая информация. Сер. 2. – 2018. – № 9.
- [Чернов, 2011] Чернов Ю.Г. Психологический анализ почерка: системный подход и компьютерная реализация в психологии, криминологии и судебной экспертизе. – М.: Генезис, 2011.

СОЗДАНИЕ ПРОТОТИПОВ ПРЕЦЕДЕНТНЫХ БАЗ ЗНАНИЙ НА ОСНОВЕ ТРАНСФОРМАЦИИ ТАБЛИЦ РЕШЕНИЙ ДЛЯ ПРОГНОЗИРОВАНИЯ РИСКА ЛЕСНЫХ ПОЖАРОВ

Н.О. Дородных (*tualatin32@mail.ru*)

О.А. Николайчук (*nikoly@icc.ru*)

А.Ю. Юрин (*iskander@icc.ru*)

Институт динамики систем и теории управления
имени В.М. Матросова СО РАН, Иркутск

Повышение эффективности построения баз знаний интеллектуальных систем поддержки принятия решений продолжает оставаться актуальной научно-технической задачей. В работе описываются применение оригинального подхода, использующего принципы модельно-ориентированной разработки и трансформаций для создания прототипов баз знаний прецедентного типа. Подход обеспечивает преобразование таблиц решений с целью получения базы прецедентов простейшего параметрического вида. Приведено описание его основных этапов и пример применения при прототипировании базы знаний сервиса прогнозирования лесных пожаров.

Ключевые слова: прецеденты, база знаний, создание прототипа экспертной системы, таблицы решений, прогнозирование риска лесных пожаров.

Введение

Проблема автоматизации построения баз знаний интеллектуальных систем сохраняет свою актуальность, несмотря на несомненные успехи в данной области [Рыбина, 2010; Голенков и др., 2014]. Для ее решения разрабатываются и применяются различные методы и средства, в том числе ориентированные на конечных пользователей [Barricelli, 2019] и реализующие модельно-ориентированные и трансформационные технологии [Дородных и др., 2019].

Прецеденты остаются одной из популярных форм представления предметных знаний, а принятие решений на основе прецедентов [Aamodt, 1994; Варшавский и др., 2009] – востребованным способом решения при-

кладных задач, ввиду ряда его достоинств. В частности, применение прецедентов обеспечивает эффективное использование накопленного опыта при отсутствии глубинных знаний и наличии только поверхностных знаний, т.е. знаний о видимых взаимосвязях между отдельными событиями и фактами в предметной области. При этом происходит прямое отображение модели предметной области, представленной, например, в концептуальной или теоретико-множественной форме, в модель прецедента, исключая сложные процедуры обучения, анализа и оценки параметров, необходимых при применении методов машинного обучения. Также применение прецедентного подхода может быть рассмотрено как поисковый способ решения задач или средство получения предварительных (промежуточных) решений с целью анализа полученных результатов и дальнейшего применения других методов.

В данной работе рассмотрено применение трансформационного подхода для создания базы прецедентов, в частности, специализация подхода из [Грищенко и др., 2016]. Рассмотренный подход предполагает последовательное пошаговое преобразование концептуальных моделей разной степени абстракции с целью их конкретизации и получения программных кодов или спецификаций. При этом в качестве промежуточной формы представления данных и знаний используются таблицы решений специализированного типа. Апробация трансформационного подхода осуществлена при решении задачи прогнозирования риска лесных пожаров.

1. Подход к созданию прецедентных баз знаний

Предлагаемый подход специализирует метод, изложенный в [Грищенко и др., 2016; Дородных и др., 2019], в контексте создания баз прецедентов и состоит из следующих основных этапов:

1) Анализ предметной области и выделение основных сущностей и отношений. Основной целью данного этапа является построение моделей предметной области. Полученные модели рассматриваются как вычислительно-независимые [Грищенко и др., 2016; Дородных и др., 2019] и могут быть представлены в виде OWL-онтологии, UML-моделей (в частности, в виде UML-диаграмм классов), деревьев и таблиц решений, канонических таблиц TabbyXL [Shigarov, 2017] или концепт карт. Выбор формы представления моделей определяется как индивидуальными предпочтениями разработчика, так и особенностями используемого инструментария. В частности, подход поддерживается комплексом программных средств, одним из которых является Personal Knowledge Base Designer [Yurin, 2020] – система прототипирования баз знаний, которая интегрирована «по данным» (в части импорта и экспорта моделей) с такими системами как Protégé, CmapTools, Xmind, IBM Rational Rose Enterprise, StarUML и TabbyXL [Shigarov, 2017].

С точки зрения классического процесса разработки баз знаний [Гаврилова и др., 2016] этот этап соответствует этапу концептуализации.

2) Формализация понятий и отношений. В нашем случае используется формализм прецедентов самого простейшего параметрического типа, обеспечивающий представление структуры проблемной ситуации в виде единственного фрейма, в которых определяются параметры (свойства, характеристики и т.п.) их значения (диапазоны значений), но не задаются связи (отношения) между параметрами (в виде семантических сетей, графов, онтологий и т.п.). При этом параметры разделены две основные части: идентифицирующую (характеризующую), которая описывает опытное знание таким образом, чтобы можно было оценить возможность его повторного использования в конкретной ситуации; обучающую (решение), которая представляет собой решение проблемы, доказательство решения (заключение), альтернативные или неудачные решения.

С точки зрения модельно-ориентированного подхода [De Silva, 2015] построенные на данном этапе модели являются платформо-независимыми и являются результатом трансформации вычислительно-независимой модели. Алгоритмы трансформации реализованы в поддерживающем подходе инструментарии, в частности PKBD [Yurin, 2020]. Соотнося с классическим процессом разработки баз знаний, этот этап соответствует этапу формализации.

Особенностью предлагаемого подхода является совместное использование графических концептуальных моделей и формализма таблиц решений. При этом для формирования таблиц решений может использоваться любой табличный редактор, в частности, Microsoft Excel.

3) Уточнение понятий и отношений с учетом целевой платформы с целью построения платформо-зависимых моделей. Количество этих моделей определяется количеством платформ, для которых создается интеллектуальная система, они являются результатом автоматических преобразований платформо-независимой модели с помощью специальных инструментов с последующей модификацией конечным пользователем.

4) Синтез кода базы знаний и спецификаций прототипа интеллектуальной системы. На этом этапе автоматически с помощью программного инструментария выполняется интерпретация структур баз знаний с получением программных кодов.

5) Тестирование и интеграция. На данном этапе полученные программные коды тестируются как в специальном программном обеспечении (в интерпретаторе PKBD), так и в готовом приложении после их интеграции.

Интеграция является единственным действием, требующим навыков программирования при использовании предлагаемого подхода, все остальные этапы могут осуществляться непрограммирующими пользователями.

2. Создание прототипа прецедентной базы знаний для прогнозирования риска лесных пожаров

Рассмотренный подход был апробирован на примере создания и отладки прототипа базы прецедентов для прогнозирования риска лесных пожаров.

Проблема прогнозирования лесных пожаров не теряет свою актуальность, так как пожары представляют серьезную угрозу для людей, инфраструктуры и окружающей среды [Dorodnykh et al., 2022; Xu et al., 2020; Johnston et al., 2020]. Лесные пожары вызываются природно-климатическими условиями (в частности, сухими грозами), неосторожным обращением с огнем местного населения при сборе ягод и грибов, сжиганием травы и т.д. Решение задачи прогнозирования лесных пожаров особенно важна для Иркутской области, территория которой имеет самый высокий лесной покров (78%) среди субъектов Российской Федерации, при этом преобладают пожароопасные хвойные насаждения (более 90% всей площади, покрытой лесом) [Тимофеева и др., 2017].

Для решения задачи прогнозирования используются различные методы и инструменты, основанные на машинном обучении, нечеткой логике, кластерном анализе и др. Все они требуют определенных условий и предварительной обработки данных, поэтому было предложено использовать прецедентный подход в контексте поискового исследования.

Далее рассмотрим этапы применения предлагаемого подхода при решении данной задачи.

На этапе анализа предметной области выделены основные сущности и отношения, произведено построение модели предметной области (рис. 1) [Dorodnykh et al., 2022].

На этапе формализации понятий и отношений была сформирована структура параметрического прецедента, который соответствует предметному понятию «пожар»:

- Описание:
 - Идентификатор (id: int);
 - Дата и время начала (обнаружения) пожара (dt: data);
 - Широта (lat: float);
 - Долгота (lon: float);
 - Территория пожара (latitude: полигон);
 - Площадь пожара (fire area: float);
 - Муниципалитеты (municipalities: текст);
 - Плотность населения (population density: число жителей на квадратный километр);

- Лесное хозяйство (forestry: наименование лесничества, участка, квартала);
- Метеостанция (weather station: номер и наименование);
- Количество осадков (RRR: миллиметры, количественные значения переведены в качественные: небольшой дождь (0,0-2), дождь (3-14), сильный дождь (15-49), очень сильный дождь (более 50) и др.);
- Сила ветра (Ff: метры в секунду, количественные значения переведены в качественные по 12 бальной шкале Ф. Бофорта: штиль (0-0,2), тихий (0,3-1,5), легкий (1,6-3,3), слабый (3,4-5,4), умеренный (5,5-7,9), свежий (8,0-10,7), сильный (10,8-13,8) и др.);
- Относительная влажность воздуха (U: %);
- Температура воздуха (T: градусы Цельсия);
- Температура точки росы (Td: градусы Цельсия);
- Направление ветра (DD: ветер, дующий с западо-юго-запада; ветер, дующий с севера; ветер, дующий с западо-юго-запада; штиль, безветрие и др.);
- Текущая погода, сообщаемая метеостанцией (WW: ливневый(ые) дождь(и) слабый(ые) в срок наблюдения или за последний час; туман или ледяной туман, небо видно, без заметного изменения интенсивности в течение последнего часа; ливень (ливни); гроза (грозы) с осадками или без них и др.);
- Атмосферное давление (Po: миллиметры ртутного столба);
- Расстояние до ближайшей автомагистрали (distance to the nearest motorway: километры, интервалы значений: 0-0,5; 0,5-3; 3-10; 10-15; более 15);
- Расстояние до ближайшей железной дороги (distance to the nearest railway: километры, интервалы значений: 0-0,5; 0,5-3; 3-10; 10-15; более 15);
- Расстояние до ближайшего водохранилища (distance to the nearest reservoir: километры, интервалы значений: 0-0,5; 0,5-3; 3-10; 10-15; более 15);
- Расстояние до населенного пункта (distance to locality: километры, интервалы значений: 0-0,5; 0,5-3; 3-10; 10-15; более 15);
- Зоны лесосеменного районирования (forest seed zoning areas: сосна, ель, лиственница, кедр);
- Класс опасности погоды (weather hazard class: V – чрезвычайная (более 10000), IV - высокая (от 4001 до 10000), III – средняя (от 1001 до 4000), II – малая (от 301 до 1000), I (до 300));
- Снежность (snowiness: малоснежная, норма, многоснежная);
- Сухая гроза (dry thunderstorm: сухая гроза);

- Решение:
 - Лесные кварталы (кв: наименование лесничества, участка, квартала);
 - Классы лесной опасности (forest hazard classes: не вероятно, наименее вероятно, маловероятно, вероятно, наиболее вероятно).

Для формирования структуры прецедента использовался StarUML. Затем диаграмма была симпортирована в РКВД (рис. 2).

Уточнение понятий и отношений с учетом целевой платформы с целью построения платформо-зависимых моделей первоначально осуществлялась в РКВД. Однако ручной ввод даже с использованием диалогов и мастеров оказался достаточно трудоемким при объеме базы прецедентов в 2240 единиц. Поэтому было решено автоматизировать процесс ввода с использованием таблиц решений и дополнительного решения в форме программного модуля, обеспечившего выгрузку определенной информации о пожарах в виде CSV-файлов.

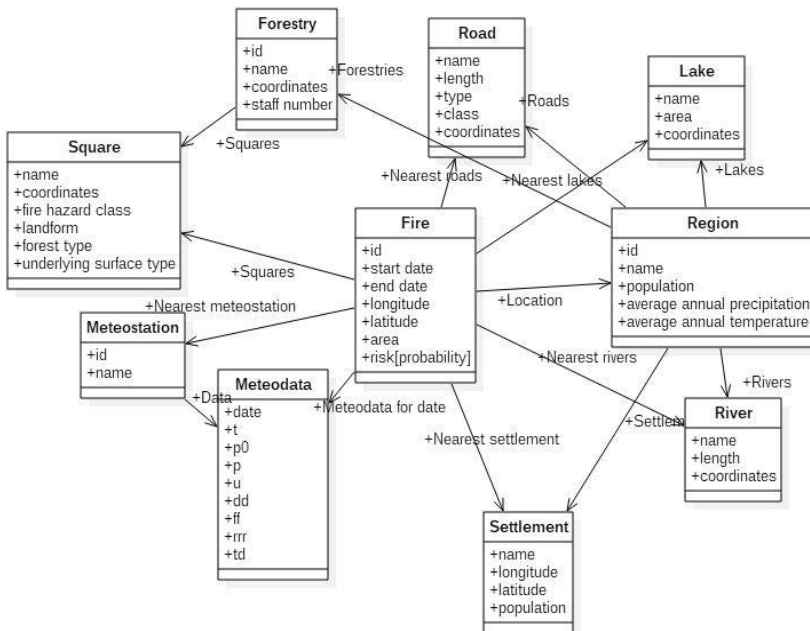


Рис. 1. Фрагмент концептуальной модели для прогнозирования риска лесных пожаров [Dorodnykh et al., 2022]

Форма таблиц решений, поддерживаемая РКВД, имеет следующие особенности [Yurin, 2020]: возможность включать столбец с именами правил в структуру таблицы; возможность указывать зависимые столбцы символом "#"; возможность указывать составные имена столбцов, включая имя сущности (или имя класса) и имя его свойства, разделенные строкой "::"; отсутствие ограничений на значения в ячейках, т. е. они могут состоять не только из набора значений {да, нет}, представляющих собой вырожденную форму таблиц истинности, но и позволяют использовать конкретные произвольные значения в качестве значений ячеек вместо только значений, указывающих на наличие или отсутствие определенного свойства (компонента) в структуре регистра.

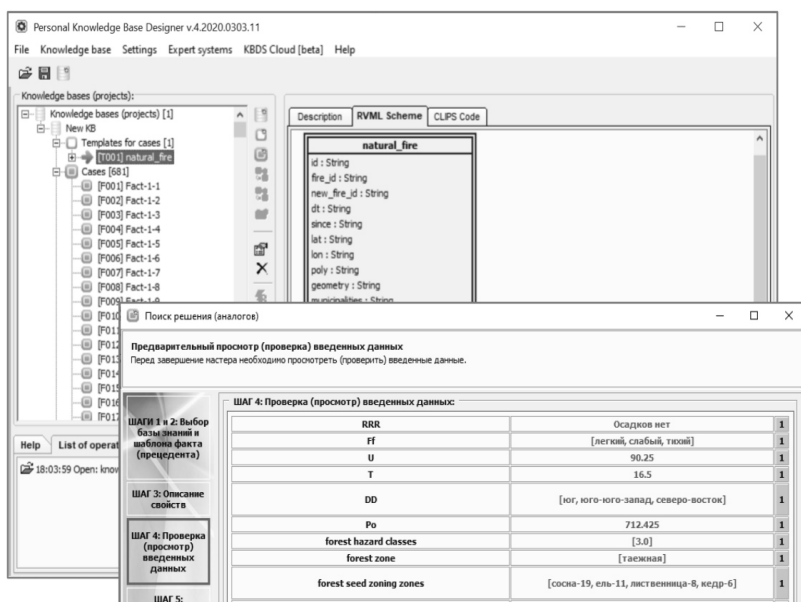


Рис. 2. Примеры форм графического интерфейса РКВД: описание шаблона (структуры) для прецедентов (лесные пожары за 2020 год); описание данных (значений свойств) прецедента

Пример таблицы решений показан на рис. 3, где каждая строка соответствует описанию отдельного прецедента.

id	dt	lat	lon	municipalities	average p	forestry	weather station n	RRR	Ff	U
66	01.04.2020 9:18	54.5235	99.1543	Нижнеудинский	1.311747		ХАДАМА	Осадков нет	тихий	84.0
71	02.04.2020 2:39	54.4849	99.2339	Нижнеудинский	1.311747		ХАДАМА	Осадков нет	тихий	96.0
72	02.04.2020 10:47	54.5033	99.2039	Нижнеудинский	1.311747		ХАДАМА	Осадков нет	тихий	96.0
73	02.04.2020 10:47	54.9613	98.893	Нижнеудинский	1.311747		ХАДАМА	Осадков нет	тихий	96.0
74	02.04.2020 10:47	56.5876	99.685	Чунский	1.315849	Чунское	НОВОЧУНКА	Осадков нет	штиль	36.0
76	03.04.2020 10:34	52.0071	104.404	Иркутский	79.984232	Иркутское	ИРКУТСК	Осадков нет	слабый	31.0
79	03.04.2020 10:34	52.8266	104.898	Эжирит-Булагат	5.816963	Усть-Ордынское	УСТЬ-ОРДЫНСКИЙ	Осадков нет	легкий	25.0
80	03.04.2020 10:35	54.4423	99.4606	Нижнеудинский	1.311747	Тулунское	ИКЕЙ	Осадков нет	штиль	83.0
81	03.04.2020 10:35	54.5233	99.2939	Нижнеудинский	1.311747		ХАДАМА	Осадков нет	тихий	95.0
82	03.04.2020 10:35	54.5154	99.227	Нижнеудинский	1.311747		ХАДАМА	Осадков нет	тихий	95.0
83	04.04.2020 3:56	52.9415	103.337	Черемховский	9.295758	Черемховское	ЧЕРЕМХОВО	Осадков нет	легкий	62.0

Рис. 3. Фрагмент таблицы решений с данными о прецедентах

В дальнейшем построенная таблица решений была импортирована в разработанную ранее структуру базы прецедентов:

4) Синтез кода базы знаний и спецификаций прототипа интеллектуальной системы. При решении предметной задачи использовались результаты отладки в форме таблиц решений в CSV-файлах.

5) Тестирование разработанной базы знаний осуществлялось в PKBD и включает в себя выполнение запросов к полученной базе прецедентов (рис. 4).

The image shows two overlapping windows from the Personal Knowledge Base Designer (PKBD) software.

The top window, titled "Поиск решения (аналогов)", displays search results for a query. It includes a table with columns for step number, fact ID, fact name, and a score. The results are as follows:

ШАГ	Fact ID	Fact Name	Score
1	[F279]	Fact-1-279	0,87
2	[F399]	Fact-1-399	0,83
3	[F408]	Fact-1-408	0,82
4	[F464]	Fact-1-464	0,81

The bottom window, titled "Personal Knowledge Base Designer", shows a detailed view of a property named "RRR". The table below represents the data shown in this window:

Свойство	w	0,87	Значение - целое	Значение - [F279]
RRR	1	1	Осадков нет	Осадков нет
Ff	1	0,33	[легкий, слабый, тихий]	тихий
T	1	0,9	16.5	18.4
Td	1	0	-	16.4
DD	1	0,33	[юг, юго-юго-запад, северо-восток]	юг
W1	1	0	-	Ливень (ливни).
W2	1	0	-	Облака покрывали более половины неба в течение одной части соответствующего периода и половину или менее в течение другой части периода.
kv	1	0	-	[Нижеинское, Верхнеинское, Верхнеинская, 485, 486, 436, 437]
forest zone	1	1	[таежная]	[таежная]
forest seed zoning zones	1	1	[сосна-19, ель-11, лиственница-8, кедр-6]	[сосна-19, ель-11, лиственница-8, кедр-6]
snowiness	1	1	малоснежная	малоснежная
snowiness-uncertainty	1	0	-	-
name locality	1	0	-	Прибойный Прибойинское

Рис. 4. Примеры форм графического интерфейса PKBD: результаты поиска аналогов; подробный предварительный просмотр результатов

Отметим, что при выполнении запросов можно определить важность отдельных свойств. Важность свойств или информационный вес – это субъективная величина, которая влияет на оценку сходства. Для его определения используется шкала [1, 100]. Как видно из рис. 4, в поиске (запросах) участвуют свойства прецедента, описывающие данные о погоде, особенности поверхности и растительности, близость инфраструктуры. Остальные параметры (широта, названия территорий и районов пожара и т.д.) используются только в качестве дополнительной информации при интерпретации результатов.

В результате поиска прецеденты ранжируются по значению сходства. На рисунке 4 показаны результаты запроса в виде списка аналогов с возможностью детализации до его подробного сравнительного предварительного просмотра.

Полученный прототип базы данных содержит информацию о 2240 природных пожарах в Иркутской области за 2017 и 2020 годы. Далее мы использовали полученную базу и модуль извлечения аналогов для прогнозирования риска лесных пожаров для Бодайбинского и Казачинско-Ленского лесничеств (рис. 5) Иркутской области.

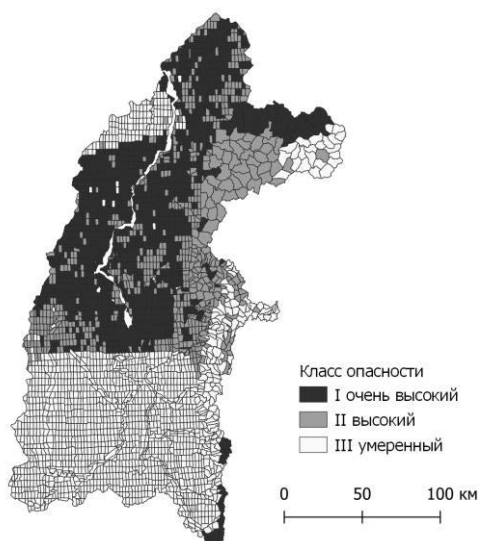


Рис. 5. Результаты прогнозирования риска пожаров с использованием разработанного прототипа базы прецедентов для Казачинско-Ленского лесничества Иркутской области [Dorodnykh et al., 2022]

Заключение

Повышение эффективности построения баз знаний интеллектуальных систем поддержки принятия решений продолжает оставаться актуальной научно-технической задачей, обуславливающей разработку новых методов и средств. В работе описываются применение оригинального подхода, использующего принципы модельно-ориентированного подхода и трансформаций, для создания прототипов баз знаний прецедентного типа. Подход обеспечивает преобразование таблиц решений с целью получения базы прецедентов простейшего параметрического вида. Приведено описание основных этапов подхода и пример его применения при прототипировании базы знаний сервиса прогнозирования лесных пожаров.

Список литературы

- [Варшавский и др., 2009] Варшавский П.Р., Еремеев А.П. Моделирование рассуждений на основе прецедентов в интеллектуальных системах поддержки принятия решений // Искусственный интеллект и принятие решений. – 2009. – № 2.
- [Гаврилова и др., 2016] Гаврилова Т.А., Кудрявцев Д.В., Муромцев Д.И. Инженерия знаний. Модели и методы – СПб.: Лань, 2016.
- [Голенков и др., 2014] Голенков В.В., Гулякина Н.А. Проект открытой семантической технологии компонентного проектирования интеллектуальных систем. часть 1: принципы создания // Онтология проектирования. – 2014. – № 1.
- [Грищенко и др., 2016] Грищенко М.А., Дородных Н.О., Николайчук О.А., Юрин А.Ю. Применение модельно-управляемого подхода для создания продукционных экспертных систем и баз знаний // Искусственный интеллект и принятие решений. – 2016. – № 2.
- [Дородных и др., 2019] Дородных Н.О., Юрин А.Ю. Технология создания продукционных экспертных систем на основе модельных трансформаций. – Новосибирск: СО РАН, 2019.
- [Рыбина, 2010] Рыбина Г.В. Инструментальные средства построения динамических интегрированных экспертных систем: развитие комплекса АТ-технология // Искусственный интеллект и принятие решений. – 2010. – № 1.
- [Тимофеева и др., 2017] Тимофеева С.С., Гармышев В.В. Экологические последствия лесных пожаров на территории Иркутской области // Экология и промышленность России. – 2017. – Т. 21, № 3.
- [Aamodt, 1994] Aamodt A., Plaza E. Case-based reasoning: foundational issues, methodological variations, and system approaches // AI Communications. – 1994. – 7 (1).
- [Barricelli, 2019] Barricelli B.R., Cassano F., Fogli D., Piccinno A. End-user development, end-user programming and end-user software engineering: A systematic mapping study / B.R. Barricelli, // Journal of Systems and Software. – 2019. – Vol. 149.

- [**De Silva, 2015**] De Silva A.R.: Model-driven engineering: A survey supported by the unified conceptual model // Computer Languages, Systems & Structures. – 2015. – No. 43.
- [**Dorodnykh et al., 2022**] Dorodnykh N., Nikolaychuk O., Pestova J., Yurin A. Forest Fire Risk Forecasting with the Aid of Case-Based Reasoning // Applied Sciences. – 2022. – 12. – P. 8761.
- [**Johnston et al., 2020**] Johnston L.M., Wang X., Erni, S., Taylor S.W., McFayden C.B., Oliver J.A., Stockdale C., Christianson A., Boulanger Y., Gauthier S. Wildland fire risk research in Canada. Environ. Rev. 2020, 28.
- [**Shigarov, 2017**] Shigarov A.O., Mikhailov A.A. Rule-based spreadsheet data transformation from arbitrary to relational tables // Information Systems. – 2017. – No. 71.
- [**Xu et al., 2020**] Xu R., Yu P., Abramson M.J., Johnston F.H., Samet J.M., Bell M.L., Haines A., Ebi K.L., Li S., Guo Y. Wildfires, global climate change, and human health // N. Engl. J. Med. – 2020, – 383.
- [**Yurin, 2020**] Yurin A.Yu., Dorodnykh N.O. Personal knowledge base designer: Software for expert systems prototyping. SoftwareX 2020, 11, 100411.

УДК 004.056

ПРИМЕНЕНИЕ ИНТЕЛЛЕКТУАЛЬНЫХ МЕТОДОВ КОРРЕЛЯЦИИ СИСТЕМНЫХ СОБЫТИЙ В ПРОГНОЗНОЙ АНАЛИТИКЕ СОСТОЯНИЙ БЕЗОПАСНОСТИ ОБЪЕКТОВ КРИТИЧЕСКИ ВАЖНЫХ ИНФРАСТРУКТУР*

И.В. Котенко (*ivkote@comsec.spb.ru*)

Д.А. Левшун (*gaifulina@comsec.spb.ru*)

Санкт-Петербургский федеральный исследовательский центр РАН,
Санкт-Петербург

В работе предлагается методика применения интеллектуальных методов корреляции системных событий, осуществляющая прогнозную аналитику состояний безопасности. Предлагаемая методика позволяет определять схожие системные события, обнаруживать между ними причинно-следственные связи и идентифицировать соответствующие состояния безопасности на ранних этапах развития сценариев событий при отказах и реализации преднамеренных угроз (атак). Для анализа сходства событий используется метод кластеризации, а для прогнозирования последовательностей событий – автокодировщик с двунаправленной рекуррентной сетью.

Ключевые слова: корреляция событий, информационная безопасность, обнаружение вторжений, машинное обучение, нейронные сети, автокодировщик, рекуррентная сеть.

Введение

Аналитика безопасности в современных информационных системах напрямую связана с возможностями своевременной и эффективной обработки больших объемов данных о системных событиях [Котенко и др., 2014; Kotenko et al., 2018]. В настоящее время большой практической важностью обладает анализ защищенности критически важных инфраструктур (КВИ). КВИ характеризуется тем, что их функционирование затрагивает, например, такие значимые сферы как государственное управ-

* Работа выполнена при финансовой поддержке РФФ в Санкт-Петербургском Федеральном исследовательском центре РАН (проект № 21-71-20078).

ление, промышленность, здравоохранение, энергетика, транспортное обеспечение. В составе таких инфраструктур находятся информационно-технические системы, отказ которых может привести к нарушению в работе всей инфраструктуры, возникновению аварийных ситуаций и большим материальным потерям. Примерами таких объектов являются различные роботизированные комплексы, системы беспилотного транспорта, сложные телекоммуникационные сети, киберфизические системы, Интернет вещей, бортовые системы управления космическими аппаратами и другие. В свою очередь отслеживание состояния безопасности объектов в КВИ требует непрерывного контроля и анализа событий с целью предсказания вероятности возможного отказа, снижения уровня надежности, а также атакующих действий.

Информация о состоянии объектов КВИ передается в виде текущих значений измерительной информации в соответствующую систему управления. Сообщение, которое содержит в себе значения измерительной информации в определенный момент времени, обозначается как системное событие. Под событием безопасности при этом понимается сообщение о возможном нарушении политики обеспечения безопасности или о наличии ранее неизвестной ситуации, которая может иметь отношение к нарушению безопасности. К подобного рода инцидентам относятся атаки и аномалии, которые могут характеризоваться различными сценариями реализации, а также осложняться пошаговым характером угроз и сокрытием злоумышленником своих следов.

Для объектов КВИ приобретает особое значение обнаружение инцидентов безопасности на ранних стадиях, кроме того, важную роль играет прогнозирование состояний безопасности [Васильев и др., 2021]. Предполагается, что объект КВИ может находиться в конечном числе заранее известных состояний в процессе своего штатного функционирования. При этом задача прогнозирования состояния сложного объекта сводится к задаче идентификации класса состояния объекта в следующий момент времени.

Перспективными методами решения описанной задачи представляются различные методы и подходы из области искусственного интеллекта (ИИ). Современные средства безопасности, основанные на искусственном интеллекте, отслеживают большое количество системных событий и должны определять те, которые могут представлять потенциальную угрозу или указывать на атаку [Браницкий и др., 2019; Kotenko et al., 2018]. Обработка событий безопасности при этом, как правило, включает в себя нормализацию, агрегацию и корреляцию.

Под процессом интеллектуальной корреляции событий в широком смысле понимается поиск взаимосвязей между отдельными событиями безопасности, который впоследствии позволяет как определить текущее

состояние безопасности объекта, так и прогнозировать последующее [Kotenko et al., 2022]. В прогнозной аналитике методы корреляции событий способны анализировать исторические данные и события в реальном времени, а также автоматически обнаруживать изменение пороговых значений. Это позволяет обнаруживать аномальные события и предотвращать нарастание сбоев и атаки на ранних стадиях.

В этом исследовании предлагается методика применения интеллектуальных методов корреляции системных событий, позволяющая осуществлять прогнозную аналитику состояний безопасности информационных объектов для их обнаружения на ранних этапах. Предлагаемая методика корреляции определять схожие системные события, обнаруживать между ними причинно-следственные связи и идентифицировать соответствующие состояния безопасности на ранних этапах развития сценариев событий. Также используются принципы обучения интеллектуальных моделей без учителя, что позволяет выявлять ранее неизвестные состояния безопасности и заблаговременно информировать о возможной угрозе.

В разделе 1 приведены релевантные исследования в области корреляции и прогнозирования состояний безопасности. В разделе 2 описывается методика применения интеллектуальных методов корреляции и используемые в оценке показатели качества. В разделе 3 проводится экспериментальная оценка предлагаемой методики.

1. Релевантные работы

Большинство исследователей рассматривают подходы к корреляции событий с точки зрения реализуемых методов [Husák et al., 2018; Kovačević et al., 2020; Москвичев и др., 2020; Федорченко и др., 2016a; Федорченко и др., 2016b]. Как правило, выделяют три основные группы методов корреляции событий: основанные на сходстве (анализируют близость событий на основе вычисления меры подобия); основанные на причинно-следственных связях (определяют последовательности взаимосвязанных во времени событий); основанные на прецедентах или знаниях (полагаются на заданные сценарии событий).

Ряд подходов сочетают в себе несколько методов корреляции событий без явного преобладания одного над другим. Как правило комбинированные подходы к корреляции предполагают, что наиболее похожие события могут быть связаны с одним и тем же сценарием атаки. При этом реализуются следующие основные процедуры: (1) идентификация связанных событий безопасности, (2) сопоставление подмножества событий с соответствующим сценарием и (3) упорядочение последовательности событий. Сходство событий при этом может определяется по ряду их атрибутов, например IP-адресам и портам источника и получателя, а причинно-

следственная связь отображаться в виде графа атаки [Haas et al., 2019]. Нередко для представления графов атак используются вероятностные модели, такие как байесовские сети [Pivarníková et al., 2020] и марковские модели [Zhang et al., 2019].

В качестве интеллектуальных моделей корреляции применяются различные модели машинного обучения, такие как случайный лес [Li et al., 2021], метод опорных векторов [Chang et al., 2016], логистическая регрессия [Oki et al., 2018], а также нейронные сети как многослойный перцептрон [Joloudari et al., 2020], сверточная нейронная сеть [Mao et al., 2021], рекуррентная нейронная сеть [Shen et al., 2018], автокодировщик [Abdullayeva, 2021] и генеративно-состязательная сеть [Zenati et al., 2018]. Методы с учителем включают фазу автоматического обучения на обучающем наборе данных событий, а методы обучения без учителя извлекают из данных правила корреляции. Для обучения без предварительных знаний подходы к корреляции для определения сходства событий также нередко используют различные методы кластеризации, в том числе нечеткую кластеризацию [Faraji Daneshgar et al., 2016], метод k-средних [Hua et al., 2017], кластеризацию на основе распространения сходства (affinity propagation) [Тао et al., 2021].

В данном исследовании в качестве механизма раннего обнаружения предлагается использовать прогнозирование системных событий на основе обучения искусственного интеллекта без учителя. Распространенными моделями подобного прогнозирования являются автокодировщики и различные виды рекуррентных сетей (Recurrent Neural Network, RNN), таких как LSTM (Long Short-Term Memory) [Du et al., 2017] и GRU (Gated Recurrent Unit) [Wang et al., 2021]. Основная идея подхода на основе автокодировщика состоит в распространении сигналов ошибки от выходов сети к ее входам и получении на выходе наиболее близкого отклика к входному. RNN, в свою очередь, реконструирует события безопасности в виде последовательности событий, упорядоченных по меткам времени. Таким образом, для прогнозирования временных сигналов видится эффективным использование автокодировщика, в качестве кодера и декодера которого используются RNN [Kromkowski et al., 2019; Zhou et al., 2021].

Разрабатываемая методика основана на применении интеллектуальных методов корреляции, осуществляющих анализ системных событий без учителя. Предлагается объединение метода корреляции на основе сходства (кластеризации событий) и причинно-следственной корреляции (автокодировщика с рекуррентными сетями).

2. Методика применения интеллектуальных методов корреляции

Можно выделить два режима работы предлагаемой методики корреляции системных событий: автономный (офлайн) и режим реального времени (онлайн). Автономный режим соответствует процессам подготовки и обучению используемых моделей и методов, а режим реального времени – процессу эксплуатации, заключающемуся в непрерывном отслеживании и прогнозировании будущих состояний безопасности на основе поступающих системных событий.

Входными данными разрабатываемой методики корреляции являются данные о системных событиях объекта, а также данные о возможных состояниях безопасности. Обозначим наблюдаемый поток системных событий E в течении времени T как множество:

$$E = \{e_1, \dots, e_T\}.$$

Пусть состояние безопасности объекта можно описать как одно из N категорий состояний безопасности объекта:

$$Y = \{y_1, \dots, y_N\}.$$

В качестве множества категорий состояний безопасности объекта может выступать как бинарное множество $Y = \{ns, as\}$, где ns – штатное состояние системы, as – состояние системы, отличное от штатного (аномалия), так и множество $Y = \{ns_1 \dots ns_d, as_1 \dots as_g\}$, где $ns_1 \dots ns_d$ – подмножество штатных состояний системы, $as_1 \dots as_g$ – подмножество, состоящее из атак (сбоев).

Поток системных событий E можно разбить на ряд временных окон:

$$S = \{s_1, \dots, s_{T+h+\tau}\},$$

где $s_t = \{e_t, \dots, e_{t+h+\tau}\}$, h – размер окна, τ – длина шага.

Выходными данными являются прогнозируемые состояния безопасности системы.

Таким образом, цель методики корреляции – предсказать состояние безопасности объекта в определенный момент времени на основе анализа событий во временном окне длиной h , предшествующему данному моменту времени:

$$\hat{y}_t = \Phi(s_{t-h}), \hat{y}_t \in Y, s_{t-h} \in S.$$

Методика применения интеллектуальных методов корреляции системных событий состоит из следующих основных этапов:

- 1) извлечение признаков системных событий;
- 2) корреляция событий на основе сходства;
- 3) причинно-следственная корреляция событий;

- 4) идентификация состояния безопасности на ранних этапах.
Рассмотрим каждый этап более подробно.

2.1. Извлечение признаков системных событий

Извлечение признаков потока осуществляется путем преобразования каждого события в потоке $e_t \in E$ в вектор x_t :

$$fe: e_t \rightarrow x_t.$$

Пусть $F^E = \{f_1, \dots, f_M\}$ – множество M признаков системных событий с областью допустимых значений $D = \{D_1, \dots, D_M\}$, так что D_m – множество допустимых значений признака f_k . Значение признака f_m определяется путем отображения $d: f_m \rightarrow D_m$. Тогда каждое системное событие $e_t \in E$ можно представить в виде вектора признаков:

$$x_t = fe(e_t) = \{d(f_1)_t, \dots, d(f_M)_t\},$$

где $d(f_m) \in D_k$ соответствует значению m -того признака события e_t .

Результатом извлечения признаков потока системных событий E является матрица векторов событий X размерностью $T \times M$ для описания состояния безопасности системы:

$$fe(E) = X = \begin{pmatrix} x_1 \\ \vdots \\ x_T \end{pmatrix} = \begin{pmatrix} d(f_1)_1 & \dots & d(f_M)_1 \\ \vdots & \ddots & \vdots \\ d(f_1)_T & \dots & d(f_M)_T \end{pmatrix}.$$

2.2. Корреляция событий на основе сходства

Корреляция событий на основе сходства основана на предположении, что состояния безопасности с высокой степенью подобия могут иметь одинаковую причину возникновения. Для определения подобия векторов событий x_1 и x_2 используется расстояние между этими векторами:

$$\rho(x_1, x_2) = |x_1 - x_2| = \sqrt{(x_1 - x_2)^2}.$$

Чем меньше расстояние между векторами событий, тем ближе данные вектора лежат в пространстве координат X , и тем более сходны соответствующие события. Оптимальное количество кластеров K определяется по минимизации критерия качества кластеризации, называемого компактностью кластеров (cluster cohesion), который определяется как сумма квадратов расстояний от образцов до центра их ближайшего кластера (within-cluster sum of squares, WSS):

$$WSS = \sum_{k=1}^K \sum_{i=1}^{|C_k|} |x_{ik} - \mu_k|^2 \rightarrow \min$$

где $|C_k|$ – размер (количество событий) кластера C_k , μ_k – вектор координат события в центре кластера C_k .

Каждому кластеру C соответствует идентификатор (метка) из множества $U = \{u_1, \dots, u_K\}$. Функция кластеризации ζ ставит в соответствие любому объекту $x_i \in X$ идентификатор кластера $u_k \in U$:

$$\zeta: X \rightarrow U.$$

Результатом корреляции события на основе сходства является преобразованная матрица X^U , в которой каждому вектору события назначена метка кластера:

$$\zeta(X) = X^U = \begin{pmatrix} x_1^u \\ \vdots \\ x_T^u \end{pmatrix} = \begin{pmatrix} d(f_1)_1 & \dots & d(f_M)_1 & \zeta(x_1) \\ \vdots & \ddots & \vdots & \vdots \\ d(f_1)_T & \dots & d(f_M)_T & \zeta(x_T) \end{pmatrix}$$

Таким образом, вводится дополнительный признак, обозначающий сходство между системными событиями. Ряд временных окон для событий с добавленным признаком S^U определяется как:

$$S^U = \{s_1^u, \dots, s_{T-h+\tau}^u\},$$

$$s_t^u = \{x_t^u, \dots, x_{t+h+\tau}^u\}.$$

2.3. Причинно-следственная корреляция событий

В качестве интеллектуальной модели прогнозирования для причинно-следственной корреляции предлагается использовать автокодировщик (autoencoder, AE) в виде двунаправленной краткосрочной памяти (bidirectional long short-term memory, Bi-LSTM). Данный тип нейронной сети позволяет проводить адекватный анализ данных в том случае, когда важные события разделены временными лагами неопределенной продолжительности. Также использование LSTM эффективнее, чем использование сверточных нейронных сетей (CNN), многослойного перцептрона (MLP) или других методов кодирования признаков, при которых теряется информация о последовательности входящих значений [Гайфулина и др., 2021].

Блоки LSTM используются для кодирования признаков системных событий X^U , поступающих на вход нейронной сети. LSTM-блоки содержат вентили f_t , i_t , o_t , реализованные в виде логистических функций, для контроля потоков информации на входах и на выходах данных блоков, а так-

же вектор состояний c_t в качестве внутренней памяти, которая обновляется с использованием текущего и предыдущего состояний:

$$LSTM = \begin{cases} f_t = \sigma_g (W_{xf} x_t^u + W_{hf} h_{t-1} + W_{cf} c_{t-1} + b_f) \\ i_t = \sigma_g (W_{xi} x_t^u + W_{hi} h_{t-1} + W_{ci} c_{t-1} + b_i) \\ o_t = \sigma_g (W_{xo} x_t^u + W_{ho} h_{t-1} + W_{co} c_{t-1} + b_o) \\ c_t = f_t \circ c_{t-1} + i_t \circ \sigma_c (W_{xc} x_t^u + W_{hc} h_{t-1} + b_c) \\ h_t = o_t \circ \sigma_c (c_t) \\ y_t = h_t \end{cases}$$

где f_t – вектор вентиля забывания (вес запоминания старой информации); i_t – вектор входного вентиля (вес получения новой информации); o_t – вектор выходного вентиля (кандидат на выход); W_{jk} – матрица весов для преобразования вектора j в компоненту вектора k ; b_j – вектор смещения вектора j ; σ_g – функция активации на основе сигмоиды; σ_c – функция активации на основе гиперболического тангенса; \circ – произведение Адамара (покомпонентное произведение двух матриц).

Bi-LSTM является расширением модели LSTM и позволяет анализировать взаимосвязи между событиями в последовательности как в прямом, так и в обратном направлении:

$$BiLSTM = \begin{cases} \vec{h}_t = LSTM(x_t^u, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = LSTM(x_t^u, \overleftarrow{h}_{t+1}) \end{cases}$$

где h_t – текущее скрытое состояние, h_{t-1} – предыдущее скрытое состояние, h_{t+1} – последующее скрытое состояние, (\rightarrow) обозначает прямое распространение информации, (\leftarrow) – обратное.

Прямая LSTM выступает в качестве кодера и пытается закодировать вектор признаков более высокого измерения в представление более низкого измерения, а обратная LSTM является декодером и восстанавливает представление вектора их обратно в исходное измерение. Таким образом, получившийся автокодировщик изучает сжатое представление входного вектора, которое содержит всю существенную информацию о входе. Прогнозирование последовательности системных событий \hat{s}_{t+1} с использованием BiLSTM осуществляется на основе анализа предшествующих событий во временном окне размерностью h , так что любой вектор в \hat{s}_{t+1} определяется как:

$$\hat{x}_{t+\tau}^u = BiLSTM(s_{t-h+\tau}^u) = \{BiLSTM(x_{t-h+\tau}^u), \dots, BiLSTM(s_{t+\tau}^u)\}, \tau = 1 \dots h$$

Визуализация данного процесса на уровне системных событий представлена на рис. 1. В данном примере размер временного окна $h = 5$, а длина шага $\tau = 1$. Сплошными линиями указано объединение событий в последовательности. Процесс прогнозирования обозначается стрелкой.

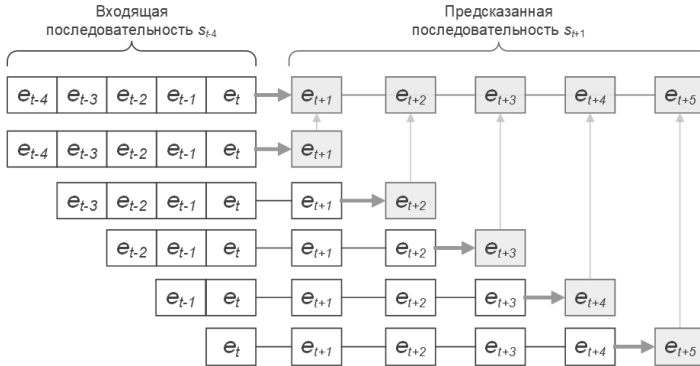


Рис. 1. Прогнозирование последовательности системных событий

2.4. Идентификация состояния безопасности на ранних этапах

Идентификация состояния безопасности на ранних этапах осуществляется путем сопоставления прогнозируемой последовательности системных событий \hat{s}_{t+1} категории безопасности $\hat{y}_t = y_{t+1}$. В отсутствие базы знаний о всех возможных нежелательных состояниях безопасности объекта, определяется отклонение текущего состояния от прогнозируемого нормального поведения как:

$$A(s_{t+1}, \hat{s}_{t+1}) = |s_{t+1} - \hat{s}_{t+1}|_A,$$

где s_{t+1} – реальная последовательность событий, \hat{s}_{t+1} – прогнозируемая последовательность событий, $|s_{t+1} - \hat{s}_{t+1}|_A$ – численный показатель, определяющий степень расхождения двух последовательностей событий.

Результат \hat{y}_t получается путем сравнения полученного показателя $A(s_{t+1}, \hat{s}_{t+1})$ с пороговым допустимым значением отклонения δ :

$$\hat{y}_t = y_{t+1} = \begin{cases} 1, & \text{если } A(s_{t+1}, \hat{s}_{t+1}) \geq \delta \\ 0, & \text{если } A(s_{t+1}, \hat{s}_{t+1}) < \delta \end{cases}.$$

где $\hat{y}_t = 0$ – обнаруженное нормальное состояние системы, $\hat{y}_t = 1$ – обнаруженное аномальное состояние системы.

2.5. Показатели качества методики корреляции

Отклонение текущего состояния от прогнозируемого нормального поведения определяется как среднеквадратичная ошибка (mean squared error, MSE) Для каждого события при вычислении MSE вычисляется квадратная разница между прогнозами и фактическими параметрами, а затем эти значения усредняются:

$$A(s_{t+1}, \hat{s}_{t+1}) = \frac{1}{h} \sum_{i=t+1}^{t+h} (x_i - \hat{x}_i)^2$$

Для оценки качества предлагаемой методики вводится ряд показателей качества, таких как точность (precision), полнота (recall), F-мера и площадь под кривой ошибок (area under the curve, AUC) для идентификации состояния безопасности на ранних этапах. При этом определяется количество правильно обнаруженных аномалий (true positive, *TP*) и ложно обнаружений аномалий (false positive, *FP*), количество правильно назначенной нормы (true negative, *TN*) и ложно назначенной нормы (false negative, *FN*). Так как часто соотношение аномальных событий к нормальным сильно мало, то возникает дисбаланс между метками состояний. В этом случае предлагается использовать средневзвешенные показатели точности, полноты и F-меры.

Средневзвешенная точность идентификации состояния безопасности определяется соответствием результатов корреляции событий безопасности реальному состоянию безопасности:

$$P_w = \frac{\frac{(TP + FN) \times TP}{TP + FP} + \frac{(TN + FP) \times TN}{TN + FN}}{TP + FP + TN + FN}$$

Средневзвешенная полнота идентификации определяется долей корректно определенных состояний среди реально последующих состояний безопасности:

$$R_w = \frac{TP + TN}{TP + FP + TN + FN}$$

Гармоническим средним показателем является F-мера, которая придает одинаковый вес средневзвешенным точности и полноте:

$$F1_w = 2 \frac{P_w \times R_w}{P_w + R_w}$$

Кривая ошибок для идентификации состояний безопасности называется ROC-кривой (receiver operating characteristic), и показателем качества является

как площадь под этой кривой – AUC. Кривая ROC отображает соотношение истинно положительной частоты (true positive rate, TPR), и частоты ложных срабатываний (*false positive rate*, FPR), которые определяются как:

$$TPR = \frac{TP}{TP + FN}, \quad FPR = \frac{FP}{FP + TN}$$

AUC можно определить как интеграл TPR по FPR [Jiang et al., 2012]:

$$\begin{aligned} AUC &= \int_0^1 (TPR)d(FPR) = \\ &= \frac{1}{(TP + FN) \times (TN + FP)} \int_0^T (TP)d(FP). \end{aligned}$$

Показатель AUC хорошо подходит для сравнения интеллектуальных моделей. Модель со случайным прогнозированием (подобно подбрасываемой монете) демонстрирует $AUC=0.5$, а модель с совершенным прогнозированием (со 100% показателями качества P , R , $F1$) обладает $AUC=1$.

3. Экспериментальная часть

Для оценки предложенной методики в качестве набора данных о событиях объекта КВИ используется HAI Security Dataset (2021) [Shin et al., 2021]. Набор собран на испытательном стенде реалистичной промышленной системы управления, дополненной симулятором аппаратного обеспечения, который имитирует выработку электроэнергии с помощью паровых турбин и гидроаккумулирующих электростанций. Для данного испытательного стенда было проведено 25 сценариев атак. Системные события, содержащие параметры 78 датчиков промышленной системы, регистрируются с частотой 1 событие в секунду.

Обучающая выборка содержит 921 603 событий нормального поведения, а тестовая – 402 005 событий, из которых 8947 (2.2%) являются аномальными (атаками). Нормализация значений признаков событий приводит к диапазону $[0...1]$. Нормализация данных осуществляется, так как дисбаланс между значениями признаков может вызвать неустойчивость работы модели и ухудшить результаты обучения.

В качестве дополнительного признака вводится метка кластера для каждого события. Оптимальное число кластеров определяется путем вычисления компактности кластеров при различных значениях k и применения «метода локтя» (точка, при которой уменьшение компактности сильно замедляется).

На рис. 2 продемонстрирован результат анализа количества кластеров для обучающей выборки. В качестве оптимального числа кластеров выбирается $k = 3$.




Рис. 2. Выбор числа кластеров системных событий

Параметры используемой модели прогнозирования AE-BiLSTM представлены в табл. 1.

Таблица 1

Гиперпараметры модели AE-BiLSTM

Параметры	Значение/Функция
Количество скрытых слоев	5
Количество блоков в слоях LSTM	L2(32), L3(16), L5(16), L6(32)
Число эпох	10
Размер пакета (batch)	64
Функция активация скрытого слоя	ReLU
Функция активации выходного слоя	softmax
Функция потерь (loss)	MSE
Метод регуляризации	dropout
Метод оптимизации	Adam

Данная нейронная сеть включает 7 слоев (L1-L7). После входного слоя (L1) первая пара скрытых слоев LSTM (L2-L3) является кодером, создающим сжатое представление входных данных. Затем используется повторяющийся векторный слой (L4) и пара LSTM в качестве декодера (L5-L6). Функция активации ReLU (Rectified Linear Unit, выпрямленная линейная единица). Для распределения сжатого репрезентативного векто-

ра по временным шагам используется последний выходной слой декодера (L7), который предоставляет реконструированные входные данные.

Предложенные в методике модели ИИ были реализованы на языке Python с использованием библиотек Tensorflow, Scikit-learn, Numpy, Pandas и Si у. Эксперименты проводились на Aer Swift SF315-52G с процессором Intel Core i5 с тактовой частотой 1,8 ГГц, ОЗУ 8 Гб и операционной системой Windows 10.

На рис. 3 продемонстрировано, как значение ошибки реконструирования MSE на тестовых данных позволяет обнаруживать anomальные состояния безопасности. Значение порогового допустимого значения ошибки установлено как $\delta=0.016$ на основе распределения ошибок прогнозирования нормального поведения.




Рис. 3. Ошибка реконструкции для разных категорий состояний безопасности

Результаты идентификации состояния безопасности на тестовых последовательностях представлены в табл. 2.

При этом даются значения показателей как в случае использования дополнительного признака (обозначается как k^+) сходства событий, так и без него.

Таким образом, можно заключить, что предлагаемая методика применения интеллектуальных методов корреляции показывает высокие показатели качества на тестовых данных. Объединение анализа сходства и причинно-следственных связей системных событий позволяет достичь лучших результатов корреляции. При использовании добавочного признака в виде метки кластера событий показатели качества возрастают.

Таблица 2

Оценка качества методики интеллектуальной корреляции

Тестовый набор	Число событий	Число атак	Показатели качества			
			P_w	R_w	$F1_w$	AUC
test-1	43 201	6	0.9873	0.9821	0.9847	0.915
test-1 (k+)			0.9920	0.9923	0.9921	0.9164
test-2	118 801	20	0.9699	0.9739	0.9719	0.8173
test-2 (k+)			0.9770	0.9796	0.9783	0.8300
test-3	108 001	8	0.9900	0.9884	0.9892	0.9252
test-3 (k+)			0.9913	0.9910	0.9911	0.9481
test-4	39 601	12	0.9759	0.9760	0.9759	0.9164
test-4 (k+)			0.9788	0.9803	0.9795	0.9542

Разрабатываемая методика позволяет идентифицировать состояния безопасности объектов на ранних этапах путем прогнозирования будущих событий и оценке их отклонения от нормального поведения. При этом методика способна обнаруживать прежде неизвестные состояния безопасности и не требует подготовленных баз знаний об атаках.

Заключение

В работе предлагается решение задачи корреляции событий безопасности с применением комбинированной методики корреляции. В качестве механизма раннего обнаружения используется прогнозирование системных событий на основе ИИ без учителя. Методика объединяет корреляцию на основе сходства путем кластеризации схожих событий и причинно-следственную корреляцию путем обучения автокодировщика с двунаправленной рекуррентной сетью. Эксперименты на наборе данных НАИ подтверждают высокое качество идентификации состояний безопасности на ранних этапах с достижением показателей $AUC=0.95$ и $F1=0.99$. Одним из направлений будущих работ является укехитубт эффективности методики и повышение интерпретируемости интеллектуальных моделей корреляции, а также валидация на различных наборах данных.

Список литературы

- [Браницкий и др., 2019] Браницкий А.А., Котенко И.В. Обнаружение сетевых атак на основе комплексирования нейронных, иммунных и нейро-нечетких классификаторов // Информационно-управляющие системы. – 2015. – № 4.
- [Васильев и др., 2021] Васильев В.И., Вульфин А.М., Гвоздев В.Е., Картак В.М., Атарская Е.А. Обеспечение информационной безопасности киберфизических объектов на основе прогнозирования и обнаружения аномалий их состояния // Системы управления, связи и безопасности. – 2021. – № 6.

- [Гайфулина и др., 2021] Гайфулина Д.А., Котенко И.В. Анализ моделей глубокого обучения для задач обнаружения сетевых аномалий интернета вещей // Информационно-управляющие системы. – 2021. – № 1 (110).
- [Котенко и др., 2014] Котенко И.В., Саенко И.Б. Создание новых систем мониторинга и управления кибербезопасностью // Вестник Российской академии наук. – 2014. – Т. 84, № 11.
- [Москвичев и др., 2020] Москвичев А.Д., Долгачев М.В. Алгоритмы корреляции событий информационной безопасности // Автоматизация процессов управления. – 2020. – №. 3.
- [Федорченко и др., 2016а] Федорченко А.В., Левшун Д.С., Чечулин А.А., Котенко И.В. Анализ методов корреляции событий безопасности в SIEM-системах. Ч. 1 // Труды СПИИРАН. – 2016. – Вып. 4 (47).
- [Федорченко и др., 2016б] Федорченко А.В., Левшун Д.С., Чечулин А.А., Котенко И.В. Анализ методов корреляции событий безопасности в SIEM-системах. Ч. 2 // Труды СПИИРАН. – 2016. – Вып. 6 (49).
- [Abdullayeva, 2021] Abdullayeva F.J. Advanced Persistent Threat attack detection method in cloud computing based on autoencoder and softmax regression algorithm // Array. – 2021. – Vol. 10.
- [Chang et al., 2016] Chang Y.C., Wang S.D. The concept of attack scenarios and its applications in android malware detection // Proc. 2016 IEEE 18th International Conference on High Performance Computing and Communications; IEEE 14th International Conference on Smart City; IEEE 2nd International Conference on Data Science and Systems (HPCC/SmartCity/DSS). – IEEE, 2016.
- [Du et al., 2017] Du M., Li F., Zheng G., Srikumar V. Deeplog: Anomaly detection and diagnosis from system logs through deep learning // Proceedings of the 2017 ACM SIGSAC conference on computer and communications security. – 2017.
- [Faraji Daneshgar et al., 2016] Faraji Daneshgar F., Abbaspour M. Extracting fuzzy attack patterns using an online fuzzy adaptive alert correlation framework // Security and Communication Networks. – 2016. – Vol. 9, No. 14.
- [Haas et al., 2019] Haas S., Fischer M. On the alert correlation process for the detection of multi-step attacks and a graph-based realization // ACM SIGAPP Applied Computing Review. – 2019. – Vol. 19, No. 1.
- [Hua et al., 2017] Hua H.H.W., Siraj M.M., Din M.M. Integration of PSO and k-means clustering algorithm for structural-based alert correlation model // International Journal of Innovative Computing. – 2017. – Vol. 7, No. 2.
- [Husák et al., 2018] Husák M., Koárková J., Bou-Harb E., Čeleda P. Survey of attack projection, prediction, and forecasting in cyber security // IEEE Communications Surveys & Tutorials. – 2018. – Vol. 21, No. 1.
- [Jiang et al., 2012] Jiang X., Menon A., Wang S., Kim J., Ohno-Machado L. Doubly Optimized Calibrated Support Vector Machine (DOC-SVM): an algorithm for joint optimization of discrimination and calibration // PloS one. – 2012. – Vol. 7, No. 11.
- [Joloudari et al., 2020] Joloudari J. H., Haderbadi M., Mashmool A., GhasemiGol M., Band S.S., Mosavi A. Early detection of the advanced persistent threat attack using performance analysis of deep learning // IEEE Access. – 2020. – Vol. 8.

- [Kotenko et al., 2018] Kotenko I., Saenko I., Branitskiy A. Framework for Mobile Internet of Things Security Monitoring based on Big Data Processing and Machine Learning // IEEE Access. – 2018. – Vol. 6.
- [Kotenko et al., 2022] Kotenko I., Gaifulina D., Zelichenok I. Systematic Literature Review of Security Event Correlation Methods // IEEE Access. – 2022. – Vol. 10.
- [Kovačević et al., 2020] Kovačević I., Groš S., Slovene K. Systematic review and quantitative comparison of cyberattack scenario detection and projection // Electronics. – 2020. – Vol. 9, No. 10.
- [Kromkowski et al., 2019] Kromkowski P., Li S., Zhao W., Abraham B., Osborne A., Brown D.E. Evaluating statistical models for network traffic anomaly detection. // Proc. 2019 systems and information engineering design symposium. – IEEE, 2019.
- [Li et al., 2021] Li S., Zhang Q., Wu X., Han W., Tian Z. Attribution classification method of APT malware in IoT using machine learning techniques // Security and Communication Networks. – 2021. – Vol. 2021.
- [Mao et al., 2021] Mao B., Liu J., Lai Y., Sun M. MIF: A multi-step attack scenario reconstruction and attack chains extraction method based on multi-information fusion // Computer Networks. – 2021. – Vol. 198.
- [Oki et al., 2018] Oki M., Takeuchi K., Uematsu Y. Mobile network failure event detection and forecasting with multiple user activity data sets // Proceedings of the AAAI Conference on Artificial Intelligence. – 2018. – Vol. 32, No. 1.
- [Pivarníková et al., 2020] Pivarníková M., Sokol P., Bajtoš T. Early-stage detection of cyber attacks // Information. – 2020. – Vol. 11, No. 12.
- [Shen et al., 2018] Shen Y., Mariconti E., Vervier P.A., Stringhini, G. Tiresias: Predicting security events through deep learning // Proceedings of the 2018 ACM SIGSAC Conference on Computer and Communications Security. – 2018.
- [Shin et al., 2021] Shin H.K., Lee W., Yun J.H., Min B.G. Two ICS security datasets and anomaly detection contest on the HIL-based augmented ICS testbed // Cyber Security Experimentation and Test Workshop. – 2021.
- [Tao et al., 2021] Tao X.L., Shi L., Zhao F., Lu S., Peng Y. A Hybrid Alarm Association Method Based on AP Clustering and Causality // Wireless Communications and Mobile Computing. – 2021. – Vol. 2021.
- [Wang et al., 2021] Wang Z., Chen Z., Ni J., Liu H., Chen H., Tang J. Multi-scale one-class recurrent neural networks for discrete event sequence anomaly detection // Proc. of the 27th ACM SIGKDD Conference. – 2021.
- [Zenati et al., 2018] Zenati H., Foo C.S., Lecouat B., Manek G., Chandrasekhar V.R. Adversarially learned anomaly detection // Proc. 2018 IEEE International conference on data mining (ICDM). – IEEE, 2018.
- [Zhang et al., 2019] Zhang Y., Zhao S., Zhang J. RTMA: Real time mining algorithm for multi-step attack scenarios reconstruction // Proc. 21st International Conference on High Performance Computing and Communications. – IEEE, 2019.
- [Zhou et al., 2021] Zhou P., Zhou G., Wu D., Fei M. Detecting multi-stage attacks using sequence-to-sequence model // Computers & Security. – 2021. – Vol. 105.

**ИССЛЕДОВАНИЕ СЛАБОСТРУКТУРИРОВАННЫХ
СОЦИАЛЬНО-ЭКОНОМИЧЕСКИХ СИСТЕМ
НА ОСНОВЕ ГИБРИДНОЙ КОГНИТИВНОЙ КАРТЫ
В КОМБИНАЦИИ С ИЗБИРАТЕЛЬНОЙ ДЕНДРИТНОЙ
НЕЙРОСЕТЬЮ***

М.Е. Мазуров (*mazurov37@mail.ru*)

А.А. Микрюков (*mikrukov.aa@rea.ru*)

Российский экономический университет, Москва

Представлены результаты математического моделирования когнитивных карт в комбинации с избирательными дендритными сетями нейронов, обладающих при определенной организации вычислительными и когнитивными свойствами. Показана возможность повышения эффективности применения модели прогнозирования развития университета на основе когнитивной карты в сочетании с избирательной дендритной сети нейронов. Предлагаемая структура гибридных когнитивных карт допускает естественное упрощение структуры за счет удаления неработающих сетевых соединений глобальной структуры, обеспечивает универсальное матричное описание сетевой математической модели, а также эффективное формирование вычислительного алгоритма и программного обеспечения для решения задач прогнозирования показателей развития университета. В ходе исследований разработана гибридная когнитивная модель сценарного прогнозирования мероприятий по достижению требуемых значений целевых показателей деятельности университета в международном институциональном рейтинге QS. Показана возможность формирования когнитивной карты на основе многослойной дендритной сети прямого распространения при наличии однонаправленных связей ее концептов. Полученные результаты позволили сформировать сценарный план необходимого ступенчатого наращивания значений целевых показателей с учетом влияющих на них латентных факторов в интервале 2020–2025 гг.

Ключевые слова: когнитивная модель, сценарное прогнозирование, целевые показатели, институциональный рейтинг, дендриты, избирательные дендритные сети нейронов.

* Работа выполнена при финансовой поддержке РФФИ (проект № 20–07–00926).

Введение

Для решения задачи исследования слабоструктурированных социально-экономических систем был обоснован метод когнитивного моделирования с использованием когнитивных карт в комбинации с избирательными нейронными сетями. Когнитивные карты представляют собой разновидность математических моделей, описывающих плохо формализуемые проблемные ситуации или сложные слабоструктурированные системы. Нейронные сети – мощный инструмент моделирования, позволяющий воспроизводить чрезвычайно сложные зависимости. В частности, нейронные сети являются нелинейными по своей природе. На протяжении многих лет линейное моделирование было основным методом моделирования в большинстве областей, поскольку для него хорошо разработаны процедуры оптимизации. В задачах, где линейная аппроксимация неудовлетворительна, линейные модели работают неприменимы. Кроме того нейронные сети достаточно эффективно справляются с "проклятием размерности", которое не позволяет моделировать линейные зависимости в случае большого числа переменных.

В статье рассмотрен процесс формирования гибридных когнитивных карт в комбинации с избирательными дендритными сетями нейронов для решения задачи прогнозирования развития университета. Предложенный подход позволяет повысить точность прогнозирования благодаря использованию в качестве входных данных нейронной сети информации от узлов нечеткой когнитивной карты [ИАС QS-analytics], [Микрюков и др., 2020], [Болотова, 2012], [Горидько и др., 2017], [Дрейпер, 2019], [Оськин, 2017]. Установлено, что когнитивные карты в общем случае представляют собой некоторые частные случаи полносвязных нейронных сетей. Множество полносвязных нейронных сетей представлено на рис. 1 в виде так называемого «зоопарка нейронных сетей» [Хайкин, 2006], [Галушкин, 2010]

Взаимосвязи в нейронной сети аналогичны взаимосвязям концептов в когнитивной карте. На рис. 2 и рис. 3 представлены полносвязная нейронная сеть с 20-ю узлами и когнитивная карта с 20-ю узлами соответственно.

Нейронная сеть с двадцатью узлами – нейронами имеет очень большое количество межэлементных связей. При исследовании больших систем это обстоятельство может приводить к значительным трудностям. Поэтому для такого класса систем целесообразно выявление наиболее существенных узлов – подсистем, что иллюстрируется рис. 3.

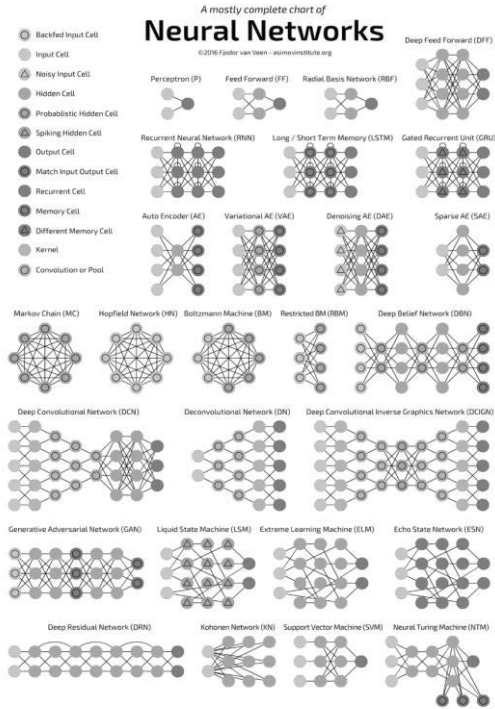


Рис. 1. Зоопарк нейронных сетей [Huff, 1990]




Рис. 2. Полностью связанная нейронная сеть с 20-ю узлами




Рис. 3. Когнитивная карта с 20-ю узлами

1. Методы построения когнитивной модели

Сформулируем свойства когнитивных карт как подсистем полносвязных нейронных сетей [Картвелишвили и др., 2018], [Мазуров, 2017], [Мазуров, 2018], [Мазуров, 2019]:

- Когнитивная карта аналог полносвязной нейронной сети с существенно меньшим числом межнейронных связей;
- Когнитивная карта это подсистемы полносвязных нейронных сетей, которые являются избирательными нейронными сетями, поскольку содержат отдельные кластеры, существенные для отражения процесса ее функционирования. Дадим краткое пояснение отличия избирательных нейронных сетей (ИНС) от стандартных нейронных сетей МакКаллока-Питса (НС). Принципиальным отличием является отсутствие необходимости в вычислении весовых коэффициентов для ИНС. Соответственно отпадает необходимость в использовании различных сложных методов для вычисления весовых коэффициентов (например, метода обратного распространения ошибки, итерационных процедур и других). Для стандартных нейронных сетей МакКаллока-Питса базовым условием работы (например, распознавание) является условие

$$\sum_{i=1}^n w_i x_i \geq U_p,$$

где (x_1, \dots, x_n) – входные сигналы; (w_1, \dots, w_n) – весовые коэффициенты; U_p – пороговое значение. Для ИНС используется условие

$$\sum_{i \in K_l} x_i \geq U_p,$$

где K_l ($l=1, \dots, L$) – знаемые кластеры нейронов. Использование второго условия для ИНС на практике, например, при решении задач распознавания не вызывает принципиальных трудостей. Но при этом решение значительно упрощается. В реальных биологических условиях использование ИНС является естественным. Более подробно свойства ИНС описаны в работах [Мазуров, 2017], [Мазуров, 2018], [Мазуров, 2019]. Рассмотрим процесс построения когнитивной модели в виде структуры типа ориентированного знакового графа на примере задачи открытия бизнеса по прокату автомобилей. Для этого выделим факторы исследуемой ситуации, а также установим связи между ними. Цель построения модели определяется на основе следующих факторов (концептов) когнитивной карты (рис. 4): 1. Спрос на прокат; 2. Тариф на

прокат; 3. Уровень конкуренции; 4. Стоимость автомобиля; 5. Спрос на автомобили; 6. Уровень доходов населения; 7. Доходы от бизнеса; 8. Спрос на транспортные услуги; 9. Тарифы на транспортные услуги; 10. Уровень безработицы; 11. Развитость малого бизнеса.

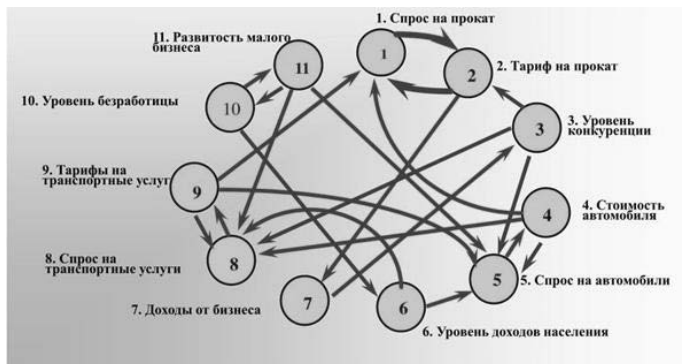


Рис. 4. Когнитивная карта в виде структурной схемы

Как построить когнитивную модель? Пользователь определяет связи между факторами в соответствии с экспертными знаниями и здравым смыслом, а также выделяет целевой концепт, например, спрос на прокат автомобилей. Связи могут быть положительными и отрицательными. При положительной связи увеличение значения фактора приводит к увеличению значения связанного с ним фактора. При отрицательной связи увеличение значения фактора приводит к уменьшению значения связанного с ним фактора.

Существует прямая и обратная задачи когнитивного моделирования. Прямая задача представляет собой прогноз развития ситуации и позволяет определить значение целевого концепта по значениям воздействий на выявленные факторы, влияющие на целевой концепт. Обратная задача заключается в нахождении управляющих воздействий на факторы исследуемой ситуации, обеспечивающие требуемое приращение целевого концепта [Кульба и др., 2002], [Горелова и др., 2010], [Кульба и др., 2004], [Трахтенгерц, 2005], [Carvalho et al., 1999], [Dombi et al., 2003], [Stach et al., 2005].

Слабоструктурированные экономические системы исследованы в классических работах Г. Саймона [Саймон, 2004] (термин слабоструктурированные задачи именно им и был предложен), О.И. Ларичева [Ларичев, 2006], Д.А. Поспелова [Поспелов, 2021] и др.), в которых рассматриваются альтернативные подходы, с самой лучшей стороны себя зареко-

мендовавшие при исследовании социально-экономических систем. В первую очередь необходимо упомянуть подход ситуационного управления, который был предложен Д.А. Поспеловым еще в начале 1970-х годов прошлого века. Кроме того, важно рассмотреть возможность использования многоагентного подхода, описанного в работах Тарасова В.Б., Макарова В.Л., Бахтизина А.Р. [Тарасов, 2002; Макаров и др, 2013], и методов вербального анализа решений, описанных в работе Ларичева О.И. По применению когнитивных карт интересные результаты получены А. Кулиничем [Кулинич, 2014].

2. Гибридные когнитивные карты в комбинации с нейронными сетями

С целью повышения качества решения задач когнитивного моделирования когнитивные карты могут комбинироваться с нейронными сетями прямого распространения, образуя гибридные модели: когнитивная карта – нейронная сеть.

Возможно использование детерминированных и нечетких когнитивных карт. Нечеткие когнитивные карты могут носить чисто экспертный характер (хотя могут и обучаться) и соответствуют модели типа «белого ящика», тогда как искусственная нейронная сеть принципиально ориентирована на обучение (модель типа «черного ящика») [Горелова и др., 2006], [Оськин, 2017], [Корноушенко и др., 2000], [Кузнецов, 2009].

Дальнейшие исследования показали целесообразность использования нейронных сетей следующих типов: многослойных нейронных сетей прямого распространения перцептронов, нейронных сетей Коско и Хопфилда [Хайкин, 2006], [Галушкин, 2010], [Carlsson et al., 1996] [Tolman, 1995]. [Axelrod, 2016] [Kosko, 1986].

Использование нейронных сетей в комбинации с когнитивными картами является избыточным в том плане, что нейронная сеть используется в качестве системы сумматоров, а нелинейные элементы нейронов в составе нейронной сети не используются.

При оценке качества социально-экономических систем, например, при оценке рейтинга университетов использование нелинейных пороговых свойств нейронов может не потребоваться. В таких случаях целесообразно использование дендритных нейронных сетей, состоящих из связывающих сетевых элементов – дендритов. Приведем более подробное описание дендритных нейронных сетей. [Мазуров, 2018], [Осовский, 2002], [Stuart et al., 1999].

Дендритные сети, как показали последние исследования, могут быть очень сложными и выполнять определенные когнитивные функции [Segev et al., 1995], [Tuckwell et al., 1988], [Sjostrom et al., 2008]. При этом сети из

дендритов могут иметь сложную иерархическую структуру, каждый уровень которой может выполнять определенные когнитивные функции [Hausser, 2000], [London et al., 2005], [Mel, Bartlett, 1994]. Для лучшего представления дендритных сетей в нейронах приведем иллюстрации некоторых дендритных сетей нейронов. Они приведены на рис. 6.




Рис. 6. Строение дендритов нейрона: a – однослойная сеть дендритов; b, c – двухслойные сети; d, e – трехслойные сети; f, g – сложные многослойные сети дендритов нейронов мозга; h – показаны дендриты, подходящие извне к дендритной сети нейрона мозжечка для формирования сложных управляющих воздействий

Из приведенного описания иерархической структуры некоторых дендритных сетей вытекает, что эти они обладают обширными возможностями обработки входной информации, а также возможностями управления процессами отклика нейрона на входную информацию. Дендритные сети имеют, как правило, иерархический характер.

3. Когнитивная модель прогнозирования развития университета на основе комбинации когнитивной карты и избирательной дендритной сети нейрона

Разработанная когнитивная модель прогнозирования деятельности университета предназначена для обеспечения повышения рейтинга университета в международном институциональном рейтинге QS до требуемых значений. Оценка рейтинга университетов осуществляется с помощью системы QS World University Rankings, которая публикуется с 2004 года [ИАС QS - analytics]. Для вычисления рейтинга университета используются следующие показатели, называемые главными факторами: 1. Ака-

демическая репутация; 2. Репутация у работодателя; 3. Соотношение между количеством преподавателей и количеством студентов. 4. Показатель цитируемости преподавателей; 5. Число международных преподавателей; 6. Число международных студентов. Для оценки рейтинга университета используется функционал вида

$$y = w_1 x_1 + w_2 x_2 + w_3 x_3 + w_4 x_4 + w_5 x_5 + w_6 x_6, \quad (1)$$

где $w_1, w_2, w_3, w_4, w_5, w_6$ - весовые коэффициенты задаются, согласно рекомендациям QS, равными соответственно 0, 4; 0,1; 0,2; 0,2; 0,05; 0,05 [ИАС QS - analytics].

Для оценки рейтинга используют линейный функционал (1). При использовании нелинейных сетей их нелинейные свойства не потребуются. Поэтому целесообразно использование дендритных нейронных сетей, которые не содержат нелинейных элементов.

Построена когнитивная модель, отражающая взаимосвязи выявленных латентных факторов, целевых показателей и функционала. Предложена гибридная интеллектуальная система прогнозирования развития университета на основе когнитивной карты в комбинации с дендритными сетями нейрона и показана на рис. 7 [Мазуров, 2017], [Yarushev, et al., 2016], [Ефремова и др., 2017].




Рис. 7. Гибридная интеллектуальная система прогнозирования развития университета на основе комбинации когнитивной карты и избирательной дендритной сетью нейрона

На рис. 7 приняты следующие обозначения: $F(i)$ – латентные факторы, формирующие главные факторы AR – Академическая репутация; PP – Репутация у работодателя; OSB – Соотношение между количеством преподавателей и количеством студентов; CP – Показатель цитируемости преподавателей; MP – Число международных преподавателей; MS – Число международных студентов для расчета результирующего рейтинга F .

В гибридной системе не учитываются влияния обратных связей от главных факторов. Обычно это влияние не является значительным и в первом приближении их можно не учитывать. Если влияние обратной связи является заметным, то его можно учесть введением дополнительных связей, как это делается для нейронных сетей Хопфилда.

Структура гибридной когнитивной карты общего вида с учетом латентных факторов первого порядка, влияющих на значения главных факторов, показана на рис. 8.

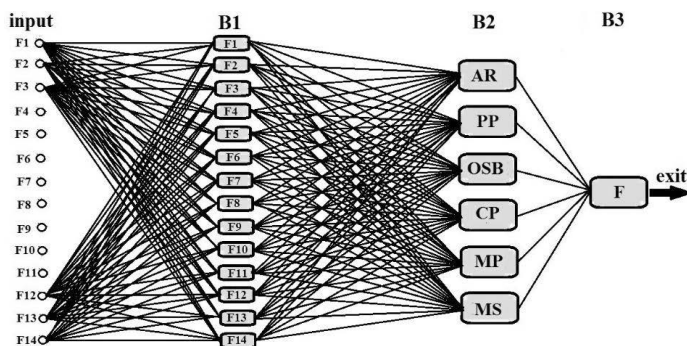


Рис. 8. Структура гибридной когнитивной карты общего вида с учетом факторов первого и второго порядков в комбинации с дендритной сетью нейрона. На карте показаны связи входов $F1, F2, F3$, а также входов $F12, F13, F14$. Связи от остальных входов на рисунке не показаны. Обозначения латентных факторов такие же, как на рис. 7

Предлагаемая когнитивная карта не учитывает влияния обратной связи от главных факторов. Обычно это влияние не является значительным и в первом приближении его можно не учитывать. Если влияние обратной связи является заметным, то его можно учесть введением дополнительных связей, как это делается для нейронных сетей Коско [Kosko, 1986] .

Некоторые латентные факторы из числа учитываемых оказывают заметное влияние только на некоторые главные факторы и не оказывают влияние на другие главные факторы. Избирательный характер влияния латентных факторов можно учесть избирательной кластеризацией связей

в когнитивной карте путем удаления несущественных связей. В результате когнитивная карта в целом упрощается и становится более наглядной. Когнитивная карта с удаленными несущественными связями приведена на рис. 9.

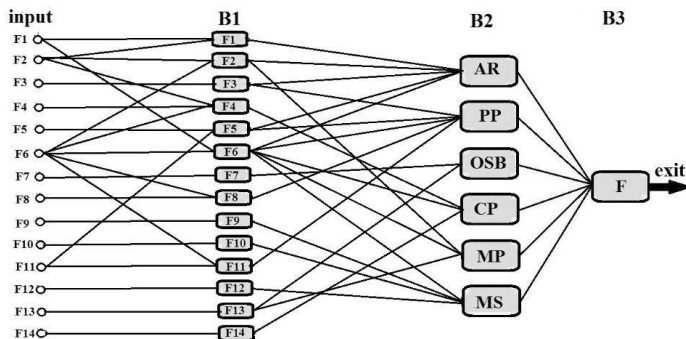


Рис. 9. Структура гибридной когнитивной карты с удаленными несущественными связями. На рисунке приняты те же обозначения факторов, как и на рис. 7

Ниже рассмотрен математический метод описания процессов, происходящих в системе моделируемой гибридной когнитивной карты.

4. Описание гибридной когнитивной карты в комбинации с дендритной сетью нейрона

На вход дендритной сети подаются значения латентных факторов $x_i = (x_{i1}, \dots, x_{im})$, ($i=1, \dots, m$). Число n равно числу лет, когда эти факторы рассматривались.

Производится формирование сумм исходя из матричного уравнения

$$S = WX, \quad (2)$$

где W – матрица весовых коэффициентов, $X = (x_1, \dots, x_m)$,

$$S_i = \sum_{j=1}^n w_{ij} x_{ij}, \quad (i=1, \dots, m). \quad (3)$$

Формирование сумм S_i можно сравнить со сложением сигналов в узлах дендритного дерева нейрона. В окончательном блоке производится формирование функционала ошибки

$$F = \sum_{j=1}^n (y_j - (a_0 + \sum_{i=1}^m (a_i x_{ij}))^2. \quad (4)$$

тация у работодателя; *ОСП* – Соотношение между количеством преподавателей и количеством студентов; *ЦП* – Показатель цитируемости преподавателей; *МП* – Число международных преподавателей; *МС* – Число международных студентов.




Рис. 10. Графики изменения рейтингового функционала университетов РЭУ, ВШЭ, РУДН, КФУ

Воспользуемся динамикой главных факторов университета РУДН за 5 лет 2015–2019 гг., показанных на рис. 9.




Рис. 9. Динамика главных факторов университета РУДН за 5 лет 2015–2019 гг.

Значения главных факторов приведены в табл. 1.

Таблица 1

№	Годы	<i>F</i>	<i>AP</i>	<i>PP</i>	<i>ОСП</i>	<i>ЦП</i>	<i>МП</i>	<i>МС</i>
1	2015	28.0	17.3	27.0	86.9	1.2	7.5	7.0
2	2016	29.0	17.6	26.8	90.1	1.4	10.0	8.3
3	2017	29.1	17.7	21.3	92.7	1.5	9.3	9.8
4	2018	31.9	21.8	31.6	92.8	1.5	8.4	12.6
5	2019	31.6	19.4	28.8	96.6	1.7	10.3	14.5
6	2020	32.0	20.0	30.0	95.0	1.7	11.0	15.9

В таблице приняты обозначения главных факторов как на рис. 6. В результате расчетов, реализующих минимизацию функционала F , получена зависимость рейтингового показателя Московского Государственного Строительного Университета от главных факторов. Представляет интерес расчет рейтинга по уравнениям множественной линейной регрессии по показателям для первых 3-х, 4-х, и 5 главных факторов для данных табл. 1. В результате расчетов с использованием системы программирования Матлаб⁷ для функционала, описывающего рейтинг, были получены соотношения:

$$R=0.4767 x_1+0.0775 x_2+0.2056 x_3$$

$$R=0.4195 x_1+0.1030 x_2+0.1868 x_3+1.4415 x_4$$

$$R=0.4229 x_1+0.1023 x_2+0.1863 x_3+1.4049x_4+0.0066 x_5.$$

Весовые коэффициенты в этих соотношениях являются близкими к весовым коэффициентам функционала (1).

Рассмотрим вычисление рейтингового показателя с помощью первого уравнения. Например, подставляя данные 2019 года (19.4, 28.8, 96.6, 1.7, 10.3, 14.5) получим значение рейтингового показателя 31.341, что хорошо согласуется с табличным значением 31.6. При использовании второго уравнения получим значение рейтингового показателя 31.6, что идеально согласуется с табличным значением. Полученные зависимости позволяют прогнозировать значение рейтинговых показателей для последующих лет 2020–2021 годов по значениям главных факторов.

Приведенные расчетные данные показывают, что наиболее существенными главными факторами являются: AP – академическая репутация; PP - репутация у работодателя; $ОСП$ – отношение числа студентов к числу преподавателей. Наибольшая интенсивность роста потребуется для следующих латентных факторов: 1) Совместные научные проекты; 2) Число публикаций в БД Scopus; 3) Востребованность выпускников у работодателей. Среди латентных факторов наибольшая интенсивность роста необходима для факторов: 1) Количество НПП; 2) Площади для образовательной деятельности.

В результате выполненных расчетов можно сделать следующие выводы: для гарантированного места в рейтинге QS необходимо ступенчатое (с интервалом в один год) наращивание значений целевых показателей, влияющих на них латентных факторов.

Обсуждение полученных результатов

Анализ изменения значений главных факторов и значений рейтинга для Российского экономического университета (РЭУ) им Г.В. Плеханова показывает их недетерминированный характер. В связи с этим РЭУ по рейтингу QS уступает рейтингу других университетов, что требует необходимости принятия ряда дополнительных мероприятий для его повышения.

Разработана гибридная когнитивная модель на основе когнитивной карты в сочетании с дендритной сетью нейронов. Она может быть полезной при прогнозировании функционирования слабоструктурированных социальных систем. Рассмотренная гибридная модель может быть использована для оптимизации процессов, происходящих в системе, а также сравнения эффективности различных слабоструктурированных социальных систем. Показана возможность формирования когнитивной модели на основе многослойной дендритной сети прямого распространения при наличии однонаправленных связей концептов.

Заключение

Предложенная структура гибридных когнитивных карт обеспечивает естественное упрощение структуры за счет удаления неработающих сетевых соединений глобальной структуры, универсальное матричное описание сетевой математической модели, а также эффективное формирование вычислительного алгоритма и программного обеспечения для прогнозирования показателей деятельности и развития университета.

Для достижения поставленной цели исследования обосновано применение методов решения слабо структурированных задач на основе разработки модели прогнозирования с использованием гибридных когнитивных карт, которая позволила выбрать наиболее предпочтительную альтернативу. Предложенный подход позволяет в условиях заданных ограничений найти наиболее приемлемый сценарий планирования приращения значений функционала и целевых показателей до требуемых значений за счет воздействий на латентные факторы, обеспечивающих гарантированное достижение поставленной цели. Показана возможность формирования когнитивной карты на основе многослойной дендритной сети прямого распространения при наличии однонаправленных связей концептов.

В ходе исследования решена задача разработки гибридной когнитивной модели сценарного прогнозирования мероприятий по достижению требуемых значений целевых показателей деятельности университета в международном институциональном рейтинге QS. Полученные результаты позволили сформировать сценарный план необходимого ступенчатого наращивания значений целевых показателей с учетом влияющих на них латентных факторов в интервале 2020–2025 гг.

Список литературы

- [Болотова, 2012] Болотова, Л.С.: Системы искусственного интеллекта: модели и технологии, основанные на знаниях: учебник. ФГБОУ РГУИТП; ФГАУ ГНИИ ИТТ «Информатика». – М.: Финансы и статистика, 2012.
- [Галушкин, 2010] Галушкин, А.И.: Нейронные сети. Основы теории. – М., Телеком, 2010.
- [Горелова и др., 2006] Горелова Г.В., Захарова Е.Н, Родченко С.А. Исследование слабоструктурированных проблем социально-экономических систем: когнитивный подход. – Ростов-на-Дону: Изд-во РГУ, 2006.
- [Горелова и др., 2010] Горелова, Г.В., Мельник, Э.В., Коровин, Я.С. Когнитивный анализ, синтез, прогнозирование развития больших систем в интеллектуальных РИУС // Искусственный интеллект. – 2010. – № 3.
- [Горидько и др., 2017] Горидько Н.П., Нижегородцев Р.М. Современный экономический рост: теория и регрессионный анализ: монография. – М.: Инфра-М., 2017.
- [Дрейпер, 2019] Дрейпер Н. Прикладной регрессионный анализ. – М.: Вильямс И.Д., 2019.
- [Ефремова и др., 2017] Ефремова Н.А., Аверкин А.Н., Ярушев С.А. Гибридные нечеткие когнитивные карты в задачах принятия решений и прогнозирования // Программные продукты, системы и алгоритмы. – 2017. – № 4.
- [ИАС QS-analytics] Информационно-аналитическая система QS – analyti s [Электронный ресурс] Режим доступа: <https://analytics.qs.com/#/signing>, (дата обращения 14. 07.2022).
- [Картвелишвили и др., 2018] Картвелишвили В.М., Мазуров М.Е., Петров Л.Ф.: Прикладные системно-динамические модели: монография. – М.: ФГБОУ ВО "РЭУ им. Г.В. Плеханова", 2018.
- [Корноушенко и др., 2000] Корноушенко Е.К., Максимов В.И. Управление ситуацией с использованием структурных свойств когнитивной карты // Труды ИПУ РАН. – 2000. – Т. XI.
- [Кузнецов, 2009] Кузнецов, О.П. Интеллектуализация поддержки управляющих решений и создание интеллектуальных систем // Проблемы управления. – 2009. – № 3.
- [Кулинич, 2014] Кулинич А.А. Компьютерные системы моделирования когнитивных карт: подходы и методы // Проблемы управления. – 2014. – № 3.
- [Кульба и др., 2002] Кульба В.В., Кононов Д.А., Ковалевский С.С. и др. Сценарный анализ динамики поведения социально-экономических систем, – М.: ИПУ РАН, 2002.
- [Кульба и др., 2004] Кульба В.В., Кононов Д.А., Косяченко С.А., Шубин А.Н. Методы формирования сценариев развития социально-экономических систем. – М.: СИНТЕГ, 2004.
- [Ларичев, 2006] Ларичев О.И. Вербальный анализ решений. – М.: Наука, 2006. – 181 с.
- [Мазуров, 2017] Mazurov M.E. Intelligent Recognition of Electrocardiograms Using Selective Neuron Networks and Deep Learning // International Conference of Artificial Intelligence, Medical Engineering, Education. Moscow, Russia. – 2017– P. 182-198.

- [Мазуров, 2018] Мазуров М.Е. Нелинейная динамика, почти-периодическое суммирование, автоколебательные процессы, информационное кодирование в избирательных импульсных нейронных сетях // Известия РАН. Сер. физическая. – 2018. – Т. 82, № 11. – С. 1564-1570..
- [Мазуров, 2019] Мазуров М.Е.: Идентификация математических моделей нелинейных динамических систем: монография. – М.: ЛЕНАНД. – 2019.
- [Макаров и др. 2013] Макаров В.Л., Бахтизин А.Р. Социальное моделирование – новый компьютерный прорыв (агент-ориентированные модели). – М.: Экономика, 2013. – 295 с.
- [Микрюков и др., 2020] Микрюков А.А., Гаспариан М.С., Карпов Д.С.: Разработка предложений по продвижению университета в международном институциональном рейтинге QS на основе методов статистического анализа // Статистика и Экономика. – 2020. – 17 (1)..
- [Осовский, 2002] Осовский, С. Нейронные сети для обработки информации: пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002.
- [Оськин, 2017] Оськин, А.Ф., Оськин, Д.А.: Применение нечетких когнитивных карт для моделирования плохоструктурированных систем // Вестник Полоцкого государственного университета, серия С. – 2017.
- [Поспелов, 2021] Поспелов Д.А. Ситуационное управление. Теория и практика. – 2-е изд. – М.: URSS, 2021. – 288 с.
- [Саймон, 2004] Саймон Г. Науки об искусственном. – 2-е изд. – М.: Эдиториал УРСС, 2004. – 144 с.
- [Тарасов, 2002] Тарасов В. Б. От многоагентных систем к интеллектуальным организациям: философия, психология, информатика. – М.: Эдиториал УРСС, 2002. – 352 с.;
- [Трахтенгерц, 2005] Трахтенгерц, Э.А.: Компьютерная поддержка формирования целей и стратегий. – М.: СИНТЕГ. – 2005.
- [Хайкин, 2006] Хайкин С. Нейронные сети: полный курс.. – 2-е изд. – М.: Вильямс, 2006.
- [Axelrod, 2016] Axelrod R. Structure of Decision: the cognitive maps of political elites. – N.Y.: Princeton Univ. Press, 2016. – 422 p.
- [Carlsson et al., 1996] Carlsson C., Fuller R. Adaptive fuzzy cognitive maps for hyperknowledge representation in strategy formation process. Proc. Intern. Panel Conf. on Soft and Intelligent Computing, Technical Univ. of Budapest. – 1996.
- [Carvalho et al., 1999] Carvalho J.P. and Tom J.A.B., Rule Based Fuzzy Cognitive Maps - Fuzzy Causal Relations. // Computational Intelligence for Modelling, Control and Automation: Evolutionary Computation & Fuzzy Logic for Intelligent Control, Knowledge Acquisition & Information Retrieval, edited by M. Mohammadi an, IOS Press. – 1999.
- [Dombi et al, 2003] Dombi J., Dombi J.D. Cognitive maps based on pliant logic // I.J. of Simulation. – 2003. – Vol. 6, No. 6.
- [Hausser, 2000] Hausser M. Diversity and Dynamics of Dendritic Signaling (англ.) // Science. 27 October. 2000. – Vol. 290. – Doi: 10.1126/science.290.5492.739.
- [Huff, 1990] Huff A.S. Mapping strategic thought. – Chichester: Wiley, 1990.
- [Kosko, 1986] Kosko B. Fuzzy Cognitive Maps // International Journal of Man-Machine Studies. – 1986. – No. 24.

- [**London et al., 2005**] London, Michael and Häusser, Michael. Dendritic computation (англ.) // Annual Review of Neuroscience. – 2005. – Vol. 28, No. 1.
- [**Mel, Bartlett, 1994**] Mel, Bartlett W. Information Processing in Dendritic Tree // Neural Computation. – 1994. – Vol. 6, No. 6..
- [**Segev et al., 1995**] Segev I., Rinzel J. and Shepherd G. The Theoretical Foundation of Dendritic Function: Selected Papers of Wilfrid Rall with Commentaries (англ.). MIT Press, 1995.
- [**Sjostrom et al., 2008**] Sjostrom P.J., Rancz E.A., Roth A., Häusser M. Dendritic Excitability and Synaptic Plasticity (англ.) // Physiological Reviews (англ.) русск.: journal. – 2008. – Vol. 88, No. 2.
- [**Stach et al., 2005**] Stach W., Kurgan L., Pedrycz W., Reformat M. Genetic learning of fuzzy cognitive maps // Fuzzy Sets and Systems. – 2005. – No. 153.
- [**Stuart et al., 1999**] Stuart G., Spruston N., Häusser M. Dendrites (англ.). – Oxford University Press, 1999.
- [**Tolman, 1995**] Tolman E.C. Cognitive maps in rats and men // Psychological Review. – 1995. – Vol. 2.
- [**Tuckwell et al., 1988**] Tuckwell, Henry C.: Introduction to Theoretical Neurobiology: Volume 1, Linear Cable Theory and Dendritic Structure (англ.). – Cambridge University Press, 1988.
- [**Yarushev, et al., 2016**] Yarushev S.A., Averkin A.N.: Review of studies on time series forecasting based on hybrid methods, neural networks, and multiple regression // Программные продукты и системы. – 2016. – № 1 (англ).
- [**Zhenbang, et al., 2007**] Zhenbang Lu, Lihua Zhou. Advanced Fuzzy Cognitive Maps Based on OWA Aggregation // Intern. Jour. Computational Cognition. – 2007. – Vol. 5, No. 2.

РАЗРАБОТКА СИСТЕМЫ ПО ДЕТЕКЦИИ НЕПРИГОДНОГО МРАМОРНОГО КАМНЯ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

А.С. Мохов (*mokhovas@mpei.ru*)

Д.А. Шестов (*shestovda@mpei.ru*)

И.В. Шубин (*ShubinIV@mpei.ru*)

Национальный исследовательский университет «МЭИ», Москва

Данная работа посвящена вопросам выбора и настройки сверточной нейронной сети для распознавания непригодного для обработки мрамора на конвейерной ленте, а также созданию приложения по выдаче координат непригодной породы для удаления с ленты.

Ключевые слова: сверточные нейронные сети, детекция объектов, классификация данных, обработка мрамора.

Введение

В данный момент на большинстве предприятий по обработке мраморного камня для его дальнейшего использования в составе сухих строительных смесей и отделочных материалов, задача по сортировке решается операторами людьми. Определение непригодной мраморной породы проводится на основании доли нежелательных включений жёлтого и чёрного цвета.

Таким образом на качество сортировки может влиять человеческий фактор – усталость, невнимательность и другие, что, в свою очередь, может негативным образом отражаться на качестве готовой продукции.

В связи с этим, в работе проводится исследование и разработка системы на основе свёрточных нейронных сетей, позволяющая выявлять непригодную породу по видео с конвейерной ленты.

Уточним условия задачи, которая решалась в данной работе. Данные требования являются моделированием условий процесса сортировки мрамора, который применяется на одном из предприятий по переработке мрамора для производства отделочных материалов. Дана конвейерная лента шириной 650 мм, движущаяся со скоростью 0.6 м/с. По конвейерной ленте в один слой движется поток необработанного мраморного кам-

ня, фракциями от 20 до 200мм, расстояние между отдельными единицами варьируется от 30 мм до 100 мм и меняется в зависимости от загруженности линии. В потоке необработанного камня присутствуют единицы материала с желтыми и черными включениями, которые составляют от 0 до 75% от всего потока материала. Разброс объясняется неравномерностью распределения материала в месторождении. Цветовая гамма конвейерной ленты значительно отличается от цветовой гаммы мраморного камня. На конвейерной ленте могут присутствовать помехи в виде мелкодисперсной мраморной пыли. Необходимо разработать решение на основе нейросетевых технологий и систем машинного зрения, которое позволит определять положение данных объектов в кадре и классифицировать их на пригодные/непригодные для использования в качестве сырьевого материала.

Для решения задачи используется следующий алгоритм:

1. Принять на вход образ, представленный изображением или видео.
2. Во входном образе распознать объекты детекции и описать эти объекты ограничивающими рамками.
3. Присвоить объектам метку одного из заранее определенных классов.
4. Повторить п. 1–3 для каждого изображения или кадра в видео, реализовав данный алгоритм в разрабатываемом в данной работе программном комплексе.
5. Вывести координаты центра ограничивающей рамки для объекта с меткой, соответствующей непригодной породе.

1. Требование к модели и описание выборки

Перед началом серии экспериментов требуется определить целевые характеристики нейросетевой модели. При формировании комплекса требований необходимо руководствоваться показателями точности, которым соответствуют специалисты, решающие задачи классификации мраморного камня вручную. В случае, если нейросетевая модель удовлетворяет данному комплексу требований, точность ее предсказаний на объектах тестовой выборки можно считать соизмеримой, либо превышающей точность предсказаний человека. Качество обучения нейросетевых алгоритмов следует оценивать по параметрам точности (*recision*) и полноты (*recall*) [Флах, 2015].

$$Precision = \frac{\sum TP}{\sum (TP+FP)} \quad (1)$$

$$Recall = \frac{\sum TP}{\sum (TP+FN)} \quad (2)$$

TP – доля верно определённых положительных объектов;
FP – доля неверно определённых положительных объектов;
FN – доля неверно определённых отрицательных объектов.

В работе будем считать, что детекция проведена верно при значении пересечения истинной и детектированной рамок IoU > 80%. На практике при обработке информации из видеофайлов и с камеры в режиме реального времени, значение IOU не опускалось ниже 95%. Под точностью детекции в данной работе мы понимаем долю верно детектированных объектов ко всему числу объектов.

Формирование выборки проводилось следующим образом:

В качестве имитации участка конвейерной ленты использовалась пластина из ПВХ пластика 650 мм x 100 мм. Для ликвидации бликов и отражений светового потока, поверхность пластины была покрыта нетканым материалом однородного чёрного цвета. В качестве источника освещения были использованы лампы общего назначения, со следующими параметрами: 60 x 110 мм, угол светового пучка 240°, световой поток 820 лм. Также был использован цифровой фотоаппарат разрешением 4320 x 3240. При формировании выборки на поверхность наносилась мраморная пыль, для имитации естественной помехи для детектора и классификатора. Экспозиция устанавливалась средней по всему кадру в автоматическом режиме.

Таким образом для обучения и проверки нейросетевых моделей была сформирована выборка из 702 изображений. Данные изображения были аугментированы, аннотированы и автоматически распределены на обучающую, валидационную и тестовую выборку с помощью вспомогательных программ в следующих объемах: 70% изображений использовались в обучающей выборке, 20% в тестовой и 10% в валидационной [Флах, 2015].

Всего для формирования выборок использовалось 2038 объектов, 1332 из которых являются пригодными, а 706, соответственно, непригодными. Пригодность образцов камня была определена в ходе экспертного анализа.

Для формирования выборки видеофайлов использовалась веб-камера с разрешением 1.3 мегапикселя. В процессе обработки на видео были наложены оптические помехи, имитирующие препятствия для детектора и классификатора. Записанные файлы использовались для проверки работоспособности программного комплекса, а также для финальной оценки метрик модели.

Исходя из оценки качества классификации оператором-человеком, полученной от специалиста с производства по переработке мраморного камня, примем следующие показатели точности и полноты в качестве целевых: точность (precision) не менее 0.93, полнота (recall) классификации не менее 0.85.

2. Выбор архитектуры нейронных сетей и проведение исследований

В данной работе рассматривались архитектуры нейросетевых моделей, способных производить детекцию и классификацию объектов в режиме реального времени. Для этого были отобраны 3 нейросетевые модели: SSD MOBILE NET V2 [Hollemans, 2018], YOLO v4 [Upesh et al., 2022], YOLO v5 [Upesh et al., 2022], [Chamidu, 2020]. Все три модели являются одноэтапными методами, в которых входные образы проходят через слои нейронной сети лишь один раз, что обеспечивает высокую скорость детекции. При этом архитектура данных моделей позволяет им сравниться в точности детекции с более эффективными многоэтапными методами.

В процессе обучения моделей производилась настройка некоторых параметров, влияющих на процесс его реализации. Методом подбора были получены значения вышеупомянутых параметров, приведённые в табл. 1. С их помощью удалось обеспечить приемлемое время реализации процесса обучения.

Таблица 1

Значения параметров обучения нейросетевых моделей

	SSD Mobilenet	YOLO v4	YOLO v5
Значение параметра скорости обучения	0.004	0.001	0.001
Объём данных, обрабатываемых за одну эпоху	6	64	16
Предельное количество эпох обучения	5000	1400	1400
Разрешение входного образа, пиксели	640*640	640*640	640*640
Целевое значение ошибки обучения	0.001	-	-
Шаг для сохранения весов	100	100	10

Параметр «Шаг для сохранения весов» измеряется в количестве итераций обучения нейронной сети. В случае, если итерация процесса обучения достигнет числа, кратного этому параметру, веса обученной нейронной сети сохранятся.

Параметр разрешения изображения был выбран в соответствии с ограничениями среды разработки Google Colab, предоставляющей бесплатный доступ к оборудованию для обучения нейросетевых моделей.

Другие параметры были заданы по умолчанию в соответствии с рекомендациями разработчиков моделей. Процесс обучения нейросетевых моделей семейства YOLO проводился с использованием программной платформы PyTorch, для обучения модели SSD MOBILENET была использована платформа TensorFlow v.2. При обучении всех трёх моделей использовался язык программирования Python 3.9. Каждая из рассмотренных выше моделей проходила процесс обучения до 10 раз, затем выбиралась модель, показатели метрик которой на валидационной выборке были максимальны.

В ходе обучения модели SSD MOBILENET было установлено, что её точность классификации объектов незначительно выше точности случайного классификатора, следовательно, её использование для решения поставленной задачи будет неэффективным. У данной модели также имеются сложности с детекцией мрамора маленьких фракций менее 30 мм, хотя по требованиям к системе, камни могут иметь размер от 20 мм.

Следующей была обучена и протестирована модель YOLO v4. В результате проверки удалось выяснить, что параметр точности классификации модели на тестовой выборке составляет 0.748, а параметр полноты 0.552. Также данная модель обладала стопроцентной точностью детекции, однако недостаточно эффективно классифицировала объекты, содержание включений в которых находилось близко к границе принятия решений.

Также была обучена и протестирована нейросетевая модель YOLO v5, которая также детектировала все объекты, поданные на вход. Отметим, что для детекции объектов с помощью данной модели пришлось доработать библиотеку YOLOv5 для стабилизации обработки данных в видеоформате и для возможности объединения всех функций в один продукт.

Параметры точности и полноты составили 0.932 и 0.867 соответственно. Также у модели были обнаружены следующие полезные свойства: возможность обрабатывать объекты, находящиеся вплотную друг к другу и объекты, частично перекрытые другими объектами, а также объекты, находящиеся в кадре не полностью. Таким образом удалось получить модель, метрики которой удовлетворяют целевым значениям. Исходя из условий задачи и принимая во внимание обнаруженные полезные свойства было принято решение закончить поиск оптимальной модели и принять обученную нейросетевую модель YOLO v5 в качестве приемлемой для разработки программных средств для решения задачи.

3. Разработанные программные средства

В ходе проведения работы был разработан программный комплекс, состоящий из пользовательского интерфейса, нейросетевой модели YOLO v5 и алгоритма трекирования. Пользователю предоставляется возможность выбрать файл с весами обученной модели, а также директорию сохранения обработанного программой видеофайла и файла со строками координат непригодной породы и временем работы в микросекундах. На вход программа может принимать как видеофайл, так и сигнал с оптического сенсора (камеры), подключённого к ПК. При подаче на вход программы видеофайла либо сигнала с камеры производится его обработка нейросетевой моделью YOLO v5 с указанными весами. При обнаружении в кадре объекта, относящегося к классу нежелательных, объект описывается ограничивающей рамкой. После чего точка пересечения диагоналей ограничивающей рамки поступает на вывод, что позволяет определить положение объекта и удалить его, если потребуется. Затем процесс повторяется для следующего кадра. После завершения обработки пользователю предоставляется возможность сохранить результат.

Разработанное ПО затем было протестировано на выборке из видеофайлов, содержащих объекты детекции, перемещающиеся по контрастному фону со скоростью 0.6 м/с. Отклонение от заданного значения скорости находилось в пределах 10%. На выборке из 160 объектов нейросетевая модель в составе программного комплекса продемонстрировала точность классификации 0.957, а также полноту классификации 0.947. Кроме того, был проведён эксперимент, в ходе которого программный код детекционного алгоритма был изменён таким образом, чтобы ограничивающей рамкой описывались также объекты положительного класса. Данный эксперимент показал, что модель также обладает стопроцентной точностью детекции.




Рис. 1. Экран окна обработки входного образа при проведении эксперимента по оценке метрик модели

Заключение

В ходе работы была выбрана и обучена модель СНС архитектуры YOLOv5 для детекции породы мрамора на конвейерной ленте, определения ее пригодности для обработки и передачи координат непригодных камней. Модель показала точность определения пригодности мрамора на уровне 0.957 и полноты на уровне 0.947. Данная модель была встроена в программную оболочку для удобства использования на производстве.

Поскольку разработанный программный комплекс позволяет получать координаты нежелательных объектов, имеется возможность для разработки автоматической или автоматизированной системы по удалению объектов с конвейерной ленты. Например, передача преобразованных координат объекта на контроллер, который в свою очередь передаст управляющее воздействие на манипулятор, осуществляющий удаление объектов.

В качестве дальнейшего развития системы предлагается исследовать качество работы при различной экспозиции кадра – более светлой или более темной, и при различных условиях освещения. Кроме того, в данной работе, в связи с ограничениями среды разработки, изображения сжимались до разрешения 640*640 пикселей. Вместе с тем, если процесс обучения нейросетевых моделей удастся провести, подав на вход изображения в их фактическом разрешении, есть вероятность повысить качество классификации.

Список литературы

- [Флах, 2015] Флах П. Машинное обучение – Наука и искусство построения алгоритмов, которые извлекают знания из данных. – М: ДМК-пресс, 2015. – 400 с.
- [Chamidu, 2020] Chamidu Supeshala YOLO v4 or YOLO v5 or PP-YOLO? // Towards Data Science. – Электронный ресурс <https://towardsdatascience.com/yolo-v4-or-yolo-v5-or-pp-yolo-dad8e40f7109> (дата обращения: 23.03.2022).
- [Holleman, 2018] Hollemans Matthijs MobileNet version 2 // MachineThink. – Электронный ресурс <https://machinethink.net/blog/mobilenet-v2/> (дата обращения: 14.03.2022).
- [Upesh et al., 2022] Upesh Nepal, Hossein Eslamiat Comparing YOLOv3, YOLOv4 and YOLOv5 for Autonomous Landing Spot Detection in Faulty. UAVs, 2022. – 15 с.

АВТОМАТИЗАЦИЯ АНАЛИЗА ПРОГРАММНОГО КОДА С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ*

В.С. Мошкин (*postforvadim@ya.ru*)

А.А. Дырnochкин (*dyrno4kin@gmail.com*)

Н.Г. Ярушкина (*jng@ulstu.ru*)

Ульяновский государственный технический университет,
Ульяновск

В работе представлено описание разработанного подхода и сервиса для интеллектуального анализа исходного кода на Python. Сервис сокращает время проверки кода за счет частичной автоматизации. Алгоритм FastText используется для получения векторных представлений текстов исходного кода. Предварительно обученная модель языка нейронной сети, основанная на архитектуре трансформера, использовалась для получения возможного назначения функции естественного языка. Классификатор, основанный на алгоритме повышения градиента, использовался для обнаружения повторяющихся заголовков. Разработанный сервис проверяет набор изменений и публикует отчеты об ошибках и дубликаты в формате комментариев набора изменений после публикации набора изменений в удаленном репозитории Git.

Ключевые слова: рецензирование программного кода, машинное обучение.

Введение

Рецензирование кода является важным процессом в разработке ПО. Благодаря рецензированию кода удается на протяжении многих лет сохранять качество и однородность кодовой базы, отлавливать дефекты на ранних этапах разработки, что сокращает по времени тестирования и исправления найденных багов.

* Работа выполнена при финансовой поддержке Минобрнауки России в рамках проекта № 075-00233-20-05 от 03.11.2020 «Исследование интеллектуального предиктивного мульти-модального анализа больших данных и извлечения знаний из различных источников».

В функции рецензента входит:

- получение информации о публикации набора изменений;
- оценка качества набора изменений и входящего в него кода;
- формирование и публикация списка замечаний к набору изменений.

Основная цель работы – сокращение времени рецензирования и оценки качества опубликованного набора изменений, снижение влияния человеческого фактора.

Объект автоматизация предполагает отслеживание событий публикации очередного набора изменений в хостинг Git-репозитория и осуществление анализа текстовой и числовой информации, содержащейся в наборе изменений:

- заголовок Pull Request (PR);
- описание PR;
- исходный программный код, измененный в рамках PR;
- перечень измененных файлов.

В настоящий момент существует общепринятое деление ошибок на три типа: синтаксические, стилистические и логические.

- Синтаксические ошибки указывают на несоответствие программного кода синтаксису определенного языка.
- Стилистические ошибки указывают на несоблюдение общепринятого стандарта при написании кода, такие ошибки не влияют на результат выполнения программы, но существенно снижают качество кода в целом.
- Программный код с логической ошибкой также является синтаксически верным, но при этом результат выполнения такого кода отличается от ожидаемого.

Первые два типа ошибок поддаются автоматизации достаточно легко, по большей части все современные средства разработки поддерживают обнаружения таких ошибок в автоматическом режиме.

Помимо наличия ошибок, одной из метрик качества кода является наличие дублирующего кода. Дублирование кода в большинстве случаев затрудняет процессы внедрения изменений, поддержки и рефакторинга [Kapsner, 2022]. В настоящее время дублирование принято разделять на 4 основных типа [Roy, 2007]:

- а) Точные копии – идентичные сегменты кода, который могут различаться пробелами, отступами и комментариями.
- б) Переименованные копии (параметризованные копии) – сегменты кода, идентичные по структуре, но различающиеся именами переменных, типов, функций и т.д.
- в) Косвенные копии получаются в результате копирования одного сегмента кода и его последующей модификации (добавление новых строк, удаление старых и т.д.), при этом результат работы обоих сегментов идентичен.

- d) Семантические копии – сегменты кода, идентичные по функциональности, но разные по реализации.

В контексте задачи повышения качества кода полезно обнаруживать любой из типов дублирования, так как даже семантическое дублирование может вызывать трудности при будущих изменениях в кодовой базе.

1. Существующие подходы автоматического рецензирования программного кода

В настоящее время не существует подходов, одновременно обнаруживающих как различные виды ошибок, так и дубликаты. Тем не менее, существуют решения, реализующие часть этой функциональности:

1. Статические анализаторы кода, основанные на правилах (`ylint`, `flake8`, `ufo style` и др.). Данные анализаторы состоят из набора простых правил и из ПО. Правила достаточно простые, они могут ограничивать излишнюю вложенность блоков в коде, указывать на несоответствие общепринятому стилю кода.

Преимущества:

- открытость исходного кода;
- популярность.

Основные недостатки:

- простота правил,
- неоднородность: каждый статический анализатор имеет свой формат правил и свой интерфейс взаимодействия;
- отсутствие интеграции с хостингами Git-репозитория, что делает данные инструменты сложно интегрируемыми в цепочку процессов конструирования ПО.

2. `Deep Code`. Данное решение является сервисом автоматического рецензирования кода. В нем используется база знаний и алгоритмы машинного обучения, которые выбирают релевантные замечания для рецензируемого кода [DeepCode, 2022].

Основные преимущества `Deep Code` это:

- интеграция с популярными хостингами Git-репозитория (GitHub, BitBucket, Gitlab) и с CI/CD-сервисами,
- поддержка нескольких языков: Python, C++, JavaScript, Java.

Недостатки:

- отсутствие бесплатного режима;
- непопулярность;
- отсутствие примеров реального использования.

Долгое время вопрос о применимости методов искусственного интеллекта к исходному программному коду оставался открытым. Но было до-

казано, что корпуса текстов с исходным программным кодом подчиняются законам, релевантным для корпусов текстов естественных языков, таким образом было показано, что языки программирования в некоторой степени похожи на естественные языки, что сделало возможным применение методов обработки естественных языков к языкам программирования (статистические и нейросетевые языковые модели, векторные представления слов и символьных N-грамм) [[Hindle, 2012].

Сразу в нескольких исследованиях было показано, что исходный программный код, отвергаемый при рецензировании, и исходный программный код с дефектами имеет значительно меньшую «натуральность», чем обычный код («натуральность» кода оценивалась с помощью кросс-энтропии) [Ray, 2022] [Hellendoorn, 2015].

Задачу автоматического рецензирования исходного программного кода и обнаружения в нем дефектов это классическая задача машинного обучения - многоклассовая классификация, где классом является признак некачественного кода (некорректное наименование переменных, использование устаревшего метода, некорректная работа с файлами и т.д.), а в качестве входных данных используется численное представление текста исходного программного кода.

В большинстве случаев используются методы из обработки естественного языка, такие как Word2Vec, GloVe и FastText.

FastText показал наибольшую эффективность в задачах обработки исходного программного кода, так как он работает на уровне символов, в то время как первые два способа работают на уровне слов (токенов) [Mikolov, 2022] [Bojanowski, 2022] [Pennington, 2014]. Благодаря данным методам, текст с программным исходным кодом возможно преобразовать в набор векторов, где каждый вектор сопоставлен с токеном в исходном тексте, при этом в вектор закодирована семантика данного токена.

2. Разработанный подход автоматического рецензирования программного кода

Основной целью проекта является сокращение трудозатрат на процессы рецензирования и анализа исходного программного кода, написанного на языке Python.

При выполнении процесса рецензирования кода происходит процесс преобразования текста исходного программного кода в представление, необходимое для алгоритма машинного обучения.

Результат работы данного алгоритма используется для формирования списка замечаний, который впоследствии публикуется в виде комментариев к набору изменений.

Для достижения поставленной цели необходимо были решены следующие задачи:

- a) Реализован алгоритм автоматического рецензирования исходного программного кода;
- b) Реализован алгоритм обнаружения дубликатов набора изменений (PR);
- c) Разработана архитектура приложения;
- d) Разработан веб-сервис для рецензирования и анализа исходного программного кода, входящего в Pull Request;

Сервис обеспечивает следующие функции:

- a) Возможность регистрации в сервисе с помощью GitHub-аккаунта.
- b) Возможность подключения, существующего GitHub-репозитория к сервису;
- c) Получение рецензии на исходный программный код, входящий в опубликованный набор изменений (Pull Request), в виде аннотаций или комментариев к опубликованному набору изменений (рис.1).

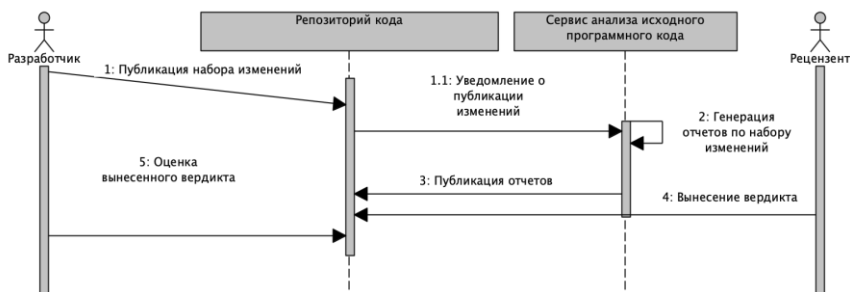


Рис. 1. Диаграмма последовательности для процесса публикации набора изменений

Для автоматического рецензирования кода использовалась нейронная сеть. Любой нейрон характеризуется следующими параметрами:

- a) Вектор входов $X = (X_1, \dots, X_n)$;
- b) Вектор выходов $O = (O_1, \dots, O_m)$;
- c) Вектор весов $W = (W_1, \dots, W_n)$;
- d) Порог срабатывания Φ ;
- e) Функция активации F ;
- f) Формула срабатывания нейрона:

$$O = F(\langle W^T, X \rangle) = F(\sum_{i=1}^n W_i * X_i),$$

$$O = \begin{cases} 1, & \langle W^T, X \rangle \geq 0 \\ 0 & \text{в остальных случаях} \end{cases},$$

Для предотвращения переобучения используется метод оптимизации RMSProp – root mean square propagation [10]:

$$RMS[g]_t = \sqrt{E[g^2]_t + e},$$

где $E[g^2]_t$ – бегущее среднее в момент t :

$$E[g^2]_t = \gamma E[g^2]_{t-1} + (1 - \gamma)g_t^2,$$

где γ – коэффициент сохранения $0 < \gamma < 1$. Чем ближе γ к единице, тем больше окно накопления и сильнее сглаживание.

Знаки препинания и специальные символы играют важную роль в программном коде, поэтому предварительная обработка кода включала преобразование кода в строчные буквы и удаление несущественных пробелов.

Для получения векторных представлений текстов исходного программного кода был использован алгоритм FastText [Elnaggar, 2022]. Особенностью данного алгоритма является работа с символьными N-граммами.

Для получения возможного назначения функции на естественном языке использовалась предобученная нейросетевая языковая модель, основанная на архитектуре трансформер [Мошкин, 2014].

Для обнаружения дубликатов PR использовался классификатор, основанный на алгоритме градиентного бустинга [Friedman, 1999].

Для вычисления меры близости между заголовком, телом, содержанием PR использовалась формула косинусного расстояния:

$$sim = \frac{A \cdot B}{||A|| \cdot ||B||}$$

Для вычисления меры близости между графом изменяемых файлов в одном PR и графов изменяемых файлов во втором PR использовалось расстояние редактирования графа [Ярушкина, 2014].

3. Программная реализация сервиса автоматического рецензирования программного кода

Система состоит из трех сервисов:

- a) Сервис идентичности, в чью зону ответственности входят процессы регистрации и аутентификации пользователей через GitHub. Написан на Go
- b) Сервис медиум, который принимает и обрабатывает события, полученные от GitHub, а также события, полученные от сервисов-анализаторов. Написан на Go

с) Сервисы анализаторы, в задачи которых входит анализ программного исходного кода и набора изменений в целом. В рамках данной работы реализовано два сервиса-анализатора: сервис, анализирующий исходный программный код и сервис, анализирующий PR в целом. Оба сервиса написаны на языке Python

Диаграмма компонентов для сервиса идентичности и сервиса медиума представлена на рис. 3.

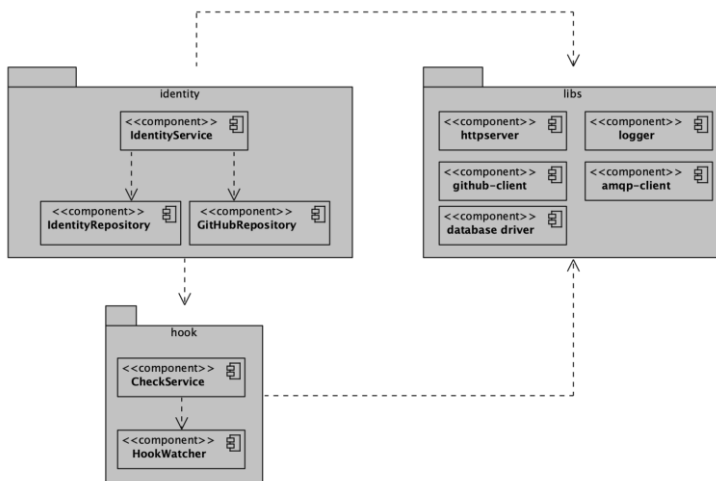


Рис. 3. Диаграмма компонентов сервиса идентичности и сервиса медиума

Диаграмма компонентов для сервисов анализаторов состоит из пакетов ml-models, entities и reviewers:

- Пакет ml-models содержит модели машинного обучения, необходимые для автоматического рецензирования и анализа программного исходного кода.
- Пакет entities содержит сущности, с которыми работает сервис. В пакете reviewers находятся классы, обеспечивающие работу с моделями машинного обучения и анализирующие исходный программный код.
- Пакет libraries состоит из используемых внешних библиотек.

Диаграмма компонентов и развертывания для сервисов анализаторов представлены на рис. 4 и 5 соответственно.

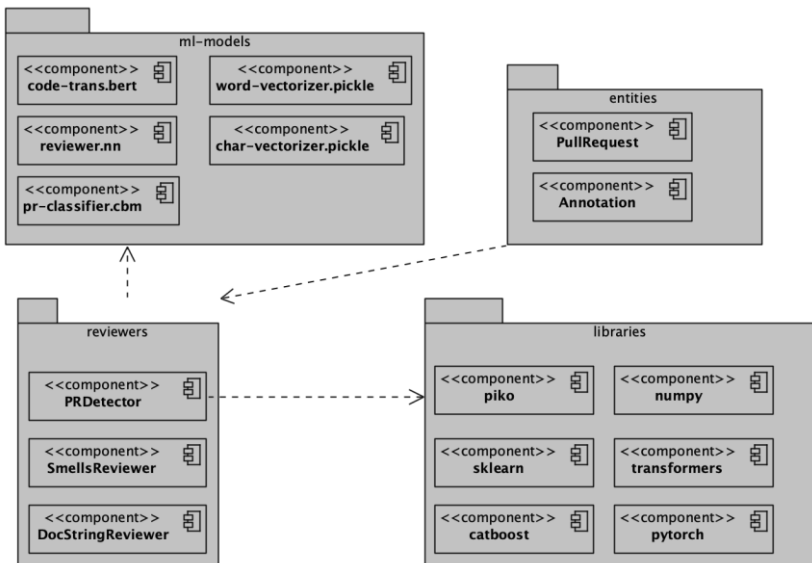


Рис. 4. Диаграмма компонентов для сервисов анализаторов

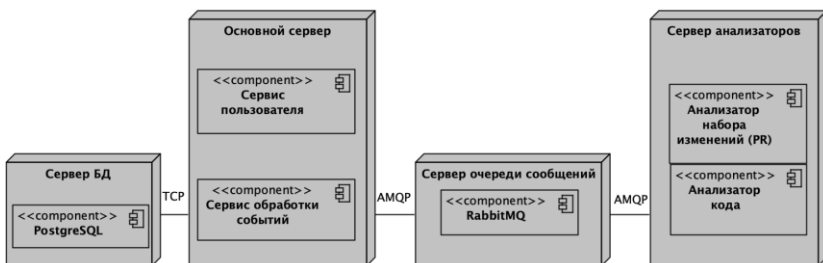


Рис. 5. Диаграмма развертывания для сервисов анализаторов

В рамках данной работы язык Python использовался для разработки сервисов анализаторов исходного программного кода.

Язык Go использовался для разработки сервиса идентичности и сервисов медиумов. Язык программирования Go — компилируемый многопоточный язык программирования, разработанный внутри компании Google.

В качестве СУБД для хранения данных использовалась реляционная СУБД открытым исходным кодом PostgreSQL.

Для передачи сообщений между сервисами использовался брокер сообщений RabbitMQ.

В качестве системы управления версиями была использована распределенная система управления версиями Git.

Также использовались следующие программные библиотеки:

- Pandas – программная библиотека на языке Python для обработки и анализа данных. Предоставляет специальные структуры данных и операции для манипулирования числовыми таблицами и временными рядами.
- Transformers – Python-библиотека для задач обработки естественного языка. Содержит множество предобученных моделей.
- Scikit-learn – библиотека машинного обучения для языка Python. Содержит реализацию многих классических моделей машинного обучения, а также инструменты для оценки качества моделей.
- PyTorch – фреймворк машинного обучения для языка Python. Позволяет разрабатывать и обучать нейронные сети.
- Piko – Python-библиотека для работы с AMQP протоколом.
- Gorilla/mux – роутер и диспетчер HTTP запросов для Go. С помощью данной библиотеки можно легко задать схему роутинга для API.
- Streadway/amqp – библиотека для языка Go, позволяющая передавать и получать сообщения по протоколу AMQP.
- Goswagger – библиотека для Go, позволяющая генерировать HTTP-обработчики по файлу спецификации swagger.
- Go-playground/webhooks – библиотека для языка Go. Позволяет настроить получение и обработку событий от GitHub.
- Google/go-github – клиент для работы с API GitHub на Go.
- Testify – библиотека для модульного тестирования в Go. Предоставляет множество инструментов для облегчения модульного тестирования.

4. Результаты контрольных экспериментов

Для обучения нейронной сети был использован набор из 103 программных проектов `python` с открытым исходным кодом из репозитория GitLab. Каждый проект на `python` включает в себя в среднем около 45 различных классов и библиотек. Классы и библиотеки имеют стандартную структуру и аналогичный набор операторов. Таким образом, обучение производилось на выборке более чем из 4600 классов `python`. Этого объема данных достаточно для обучения нейронной сети.

В качестве контрольного примера произведем процесс рецензирования и анализа набора изменений, содержащего фрагмент кода, который показан на рис. 6.

```
5 + def complicated_one(a, b, c, d, f, g, h):
6 +     return None
7 +
8 +
9 + def hello(name):
10 +     print('Hello' + name)
11 +
12 +
13 + def fac(n):
14 +     if n == 0:
15 +         return 1
16 +     else:
17 +         return n*fac(n-1)
18 +
19 + def square(x):
20 +     return x**2
21 +
22 + def read():
23 +     with open("file.txt", "r") as in_file:
24 +         buf = in_file.readlines()
25 +     return buf
26 +
27 +
28 + def tokenize_code(code: str) -> list[str]:
29 +     tokens = []
30 +     line = io.StringIO(code)
31 +
32 +     for toktype, tok, start, end, line in tokenize.generate_tokens(line.readline):
33 +         if not toktype == tokenize.COMMENT:
34 +             if toktype == tokenize.STRING:
35 +                 tokens.append("CODE_STRING")
36 +             elif toktype == tokenize.NUMBER:
37 +                 tokens.append("CODE_INTEGER")
38 +             elif (not tok == "\n") and (not tok == " "):
39 +                 tokens.append(str(tok))
40 +     return tokens
```

Рис. 6. Фрагмент кода для анализа

Для того чтобы получить анализ кода от сервиса необходимо опубликовать Pull Request. После создания Pull Request сервис опубликует анализ в виде комментариев к набору изменений. Результаты анализа кода показаны на рис. 7–9.

```
1 + import io
2 + import tokenize
3 +
4 +
5 + def complicated_one(a, b, c, d, f, g, h):
```

① Check notice on line 5 in example/example.py

neurorevizor / Neuro Revizor
example/example.py#L5
Overly complex function.

① Check notice on line 5 in example/example.py

neurorevizor / Neuro Revizor
example/example.py#L5
Unused structures.

① Check notice on line 5 in example/example.py

neurorevizor / Neuro Revizor
example/example.py#L5
Possible value : Solve a single problem

```
6 +     return None
7 +
```

Рис. 7. Пример автоматического анализа кода

На рис. 7 показан результат алгоритма обнаружения проблем для строки 5 исходного кода. Функция, инициализированная в строке №5, слишком сложна и содержит большое количество входных параметров, и в дальнейшем не используется.

```
28 + def tokenize_code(code: str) -> list[str]:
```

① Check notice on line 28 in example/example.py

neurorevizor / Neuro Revizor
example/example.py#L28
Possible value : tokenize a code string .

```
29 +     tokens = []
30 +     line = io.StringIO(code)
31 +
32 +     for toktype, tok, start, end, line in tokenize.generate_tokens(line.readline):
33 +         if not toktype == tokenize.COMMENT:
34 +             if toktype == tokenize.STRING:
35 +                 tokens.append("CODE_STRING")
36 +             elif toktype == tokenize.NUMBER:
37 +                 tokens.append("CODE_INTEGER")
38 +             elif (not tok == "\n") and (not tok == " "):
39 +                 tokens.append(str(tok))
40 +     return tokens
```

Рис. 8. Пример предсказания возможного назначения функции

На рис. 8 показан результат работы алгоритма по предсказанию возможного назначения функции, инициализированной в строке 28. Анализируемая функция служит для токенизации строки кода.

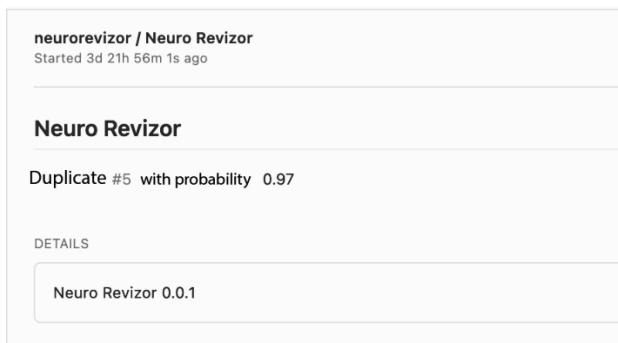


Рис. 9. Пример обнаружения дубликата Pull Request

На рис. 9 показан результат работы алгоритма обнаружения дублирующего запроса на извлечение. По результатам анализа выявлено дублирование кода проекта НейроРевизор 0.0.1 с вероятностью 97%. Результаты проверки дублирования кода известными алгоритмами и библиотеками на одном и том же тестовом образце: Dee Code показал 90%, pylint – 75%.

Заключение

В результате выполнения данной работы был разработан сервис для анализа исходного программного кода на языке Python. Сервис позволяет уменьшить время, затрачиваемое на процесс рецензирования кода с помощью частичной автоматизации данного процесса. После публикации набора изменений в удаленный Git-репозиторий сервис начинает проверку набора изменений и публикует отчеты по обнаруженным ошибкам и дубликатам в формате комментариев к набору изменений.

Реализованы следующие основные функции:

- а) Возможность аутентификации и авторизации через GitHub.
- б) Обнаружение ошибок и дефектов в программном исходном коде.
- в) Предсказание возможного назначения функции по ее коду.
- г) Обнаружение дубликатов PR в проверяемом репозитории.

Дальнейшее развитие подразумевает интеграцию с другими хостингами Git-репозитория, добавление новых типов проверок, поддержка других языков, улучшение точностей существующих моделей с помощью сбора более обширного набора данных.

Список литературы

- [**Bojanowski, 2022**] Bojanowski P. Enriching Word Vectors with Subword Information. – <https://arxiv.org/abs/1607.04606>, last accessed 2022/05/02.
- [**DeepCode, 2022**] DeepCode What is DeepCode? <https://deepcode.freshdesk.com/support/solutions/articles/60000346607-what-is-deepcode->, last accessed 2022/05/02.
- [**Elnaggar, 2022**] Elnaggar A., Ding W., Jones L., Gibbs T. Towards Cracking The Language of Silicon's Code Through Self-Supervised Deep Learning and High Performance Computing. – <https://arxiv.org/abs/2104.02443>, last accessed 2022/05/02.
- [**Friedman, 1999**] Friedman J. Greedy Function Approximation: A Gradient Boosting Machine. IM Reitz Lecture. – 1999.
- [**Hellendoorn, 2015**] Hellendoorn V.J., Devanbu P.T., Bacchelli A. Will they like this? Evaluating code contributions with language models // Will they like this? Evaluating code contributions with language models MSR '15: Proceedings of the 12th Working Conference on Mining Software Repositories. – 2015. – P. 157-167.
- [**Hindle, 2012**] Hindle A., Barr E.T., Su Z., Gabel M., Devanbu P. On the naturalness of software // ICSE '12: Proceedings of the 34th International Conference on Software Engineering. – 2012. – P. 837-847.
- [**Kapser, 2022**] Kapser C., Godfrey M. Cloning Considered Harmful Considered Harmful. – <https://ieeexplore.ieee.org/document/4023973>, last accessed 2022/05/02.
- [**Mikolov, 2022**] Mikolov T.: Efficient Estimation of Word Representations in Vector Space. – <https://arxiv.org/abs/1301.3781>, last accessed 2022/05/02.
- [**Pennington, 2014**] Pennington J., Socher R., Manning C. GloVe: Global Vectors for Word Representation // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. – 2014. – P. 1532-1543.
- [**Ray, 2022**] Ray B., Hellendoorn V. On the “naturalness” of Buggy Code. – <https://arxiv.org/abs/1506.01159>, last accessed 2022/05/02.
- [**Roy, 2007**] Roy C.K., Cordy J.R. A survey on software clone detection research // A survey on software clone detection research Queen's School of Computing Technical Report. – 2007. – P. 64-68.
- [**Мошкин, 2014**] Мошкин В.С., Ярушкина Н.Г. Особенности интеграции механизмов логического вывода в онтологическую модель представления знаний с помощью SWRL-правил // Четырнадцатая национальная конференция по искусственному интеллекту с международным участием КИИ – 2014: Труды конференции. Т. 1. – Казань: Изд-во РИЦ «Школа». – 2014. – С. 173-181.
- [**Ярушкина, 2014**] Ярушкина Н.Г., Мошкин В.С. Применение онтологического подхода к анализу состояния локальной вычислительной сети // Радиотехника. – 2014. – № 7. – С. 120-124.

ТЕХНОЛОГИИ ИНЖЕНЕРИИ ЗНАНИЙ ПРИ ДИАГНОСТИКЕ ПИЩЕВОГО ПОВЕДЕНИЯ*

Д.З. Нагаева (*nolandi@yandex.ru*)

Е.Ю. Сазонова (*ekaterina_rassadnikova@mail.ru*)

О.Н. Сметанина (*smoljushka@mail.ru*)

В.С. Сазонов (*sazonov_vladimir93@mail.ru*)

Уфимский университет науки и технологий, Уфа

В статье рассматриваются вопросы использования технологий инженерии знаний при комплексной оценке пищевого поведения. Авторами приводится анализ современного состояния в области оценки пищевого поведения, приведена постановка задачи комплексной оценки пищевого поведения и подход к ее решению. Комплексная оценка направлена на формирование выборки рекомендаций с учетом класса (тип личности). Классификация осуществляется на основе данных, собранных в результате прохождения человеком психологического теста СМЛЛ (566 вопросов, 32 оценочных шкалы). Формализация знаний с использованием продукционных моделей, осуществляется с учетом знаний экспертов о продуктах, содержащих определенные виды гормонов, и обеспечивающих улучшение настроения по сравнению с результатами прохождения теста настроения, включающего пять базовых эмоций; об улучшении качества пищевого поведения на основе результатов поведенческого текста, включающего 10 дополнительных вопросов; о продуктах, содержащих необходимые витамины, минералы и аминокислоты на основе теста на выявление питательных веществ. Полученные результаты легли в основу разработанного мобильного приложения BestBody для операционной системы Android.

Ключевые слова: технологии инженерии знаний, продукционные правила, пищевое поведение, тест СМЛЛ.

* Работа выполнена при финансовой поддержке РФ (проект № 22-19-00471).

Введение

При управлении пищевым поведением человека используются экспертные знания медицинской, социальной, психологических и других сфер [Мадкина-Пых, 2007], [Филиппов, 2013], [Васюткин, 2007]. Для решения проблемной ситуации возникающие вопросы, касающиеся этих сфер, требуют структуризации и формализации знаний для диагностики и формирования рекомендаций, и как следствие, использование технологий и методов инженерии знаний. Так, например, при анализе пищевого поведения рассматриваются вопросы о вкусовых предпочтениях, возникновении и реакции на чувство голода и насыщения, психологических особенностях личности, влияющих на прием пищи и многое другое. Рассмотренные в статье факторы влияния пищевого поведения ведут к проблеме лишнего веса, значимой и для России [Who, 2022]. Наряду с исследованиями, связанными с проблемой лишнего веса [Вознесенская, 2009], [Колеман, 2013], [Бройнинг, 2013] развиваются информационные технологии для борьбы с ним в виде калькуляторов калорий, трекеров привычек, сервисов составления диет и анализа питания [MyFitnessPal, 2022], [Fatsecret, 2022], [Lifesum, 2022]. Ни одно из предложенных решений не рассматривает вопросы комплексной оценки пищевого поведения, а также структуризации знаний и их формализации при диагностике пищевого поведения и построении рекомендаций.

В данной статье приводятся результаты анализа проблемы пищевого поведения, постановка задачи комплексной оценки пищевого поведения и подход к ее решению с использованием структуризации знаний, их визуализации и формализации экспертных знаний.

1. Анализ проблемы пищевого поведения и извлечения знаний

Для анализа проблемы пищевого поведения и извлечения знаний использованы текстологические методы, методы работы с текстом на естественном языке. Для решения стандартных задач извлечения знаний при работе с текстом на естественном языке следует выделить выявление именованных сущностей, их свойств и отношений между ними, для которых используются как готовые инструментальные средства, так и разработанные исследователями. Наиболее затратным по времени является этап подготовки текста, наиболее сложным – этап интерпретации результатов анализа текста, поясняющий контекст ситуации.

В результате детального анализа задач, решаемых с использованием популярных сервисов [Диета Онлайн, 2022] и приложений [MyFitnessPal, 2022], [Fatsecret, 2022], [Lifesum, 2022] (рис. 1) в области коррекции пи-

щевое поведение, выявлено отсутствие учета психологического и психического состояния пользователя, из чего следует, отсутствие возможности правильно подойти к формированию плана питания и анализа пищевого поведения пользователя, одного из самых важных факторов.

Рис. 1. Фрагмент сравнительного анализа программных решений в области коррекции пищевого поведения

Авторами статьи на основе анализа [Мадкина-Пых, 2007], [Бройнинг, 2013], [Вербовой и др., 2019] выявлены и структурированы основные аспекты проблем пищевого поведения, среди которых стоит выделить причины: генетическую предрасположенность, заболевание, образ жизни, пищевые привычки, социальное окружение, неудовлетворительный сон и усталость, низкая физическая активность, неудовлетворенные потребности, стресс, неумение различать физическое и эмоциональное состояние, сексуальные проблемы. Указанные причины можно разделить на 4 группы: 1) связанные со здоровьем (разного рода заболевания и нарушения); 2) связанные с режимом питания и набором потребляемых продуктов; 3) связанные с отсутствием физической нагрузки и малоподвижным образом жизни; 4) психологические (переживания, стрессы, тревожность и др.).

К следующей группе аспектов анализ [Вознесенская, 2009], [Бройнинг, 2013], [Каримов и др., 2019] позволил отнести методы диагностики лишнего веса и определения нормальной массы тела. Диагностика наличия болезни ожирения преследует следующие цели: установление факта ожирения; определение степени и типа ожирения; установление причин ожи-

рения; выявление патологических изменений внутренних органов и систем – вероятных причин и осложнений ожирения; разработка оптимальной тактики лечения ожирения. С этой целью проводится внешний осмотр, комплекс лабораторных и инструментальных исследований.

Изучение [Мадкина-Пых, 2007], [Драпкина и др., 2021] позволило выделить также такой аспект, как оценка питания. При рассмотрении данного аспекта необходимо оценить питательные вещества, энергию и энергетическую ценность продуктов, суточную потребность человека в калориях.

При анализе методов борьбы с лишним весом на основе анализа [Мадкина-Пых, 2007], [Бронникова, 2015], [Шведько, 2021], [Драпкина и др., 2021] выделены: диетологические методы; повышение физической активности; лекарственные методы; физиотерапевтические методики; биологически активные добавки (БАД); низкокалорийные питательные смеси; хирургические методы; псевдонаучные методы коррекции веса; психологические методы.

Для визуализации выявленных и структурированных знаний разработана интеллект-карта.

Выявленные и структурированные знания об использовании множества причин, факторов и методов для решения проблемы пищевого поведения положены в основу его комплексной оценки, позволяющей проводить диагностику пищевого поведения и построение рекомендаций.

2. Задача комплексной оценки пищевого поведения

Для комплексной оценки пищевого поведения необходимы базовая информация о пользователе (вес, рост, возраст, пол, степень активности) (рис. 2), используемая для первичной оценки наличия проблемы лишнего веса и расчета суточной нормы килокалорий, белков, жиров и углеводов, а также наборы вопросов для проведения тестирования пользователя. Выбор вопросов базируется на знаниях экспертов в области диетологии, нутрициологии и психологии.

Результатом комплексной оценки пищевого поведения личности являются индивидуальный набор продуктов питания для пользователя, множество советов и рекомендаций для эффективной борьбы с проблемной ситуацией, суточная норма потребления калорий, белков, жиров и углеводов, а также полное описание результатов тестов, которое может помочь пользователю лучше понять первопричины появления проблемы.

Постановка задачи в терминах теории множеств может быть представлена следующим образом:

Дано: множество $A = \{a_1, a_2, \dots, a_n\}$ – базовая информация о пользователе, множество $B = \{b_1, b_2, b_m\}$ – тестовые вопросы, множество $C = \{c_1, c_2, \dots, c_m\}$ – ответы на тестовые вопросы, знания о содержании белков, жиров, углеводов в продуктах $Z_{б\text{.ж\text{.у}}}$, знания об оценочных шкалах $Z_{ш}$.

Найти: множество правил Z'' : $A \& C \rightarrow T$ – отображение комбинации данных о пациенте в тип личности; Z' : $T \& Z_{in} \rightarrow X$ – отображение комбинации типа личности и шкалы в характеристику пациента; Z : $T \& X \rightarrow R$ – отображение рекомендации к поведению пациента.

При постановке задачи на этапе концептуализации создания программного решения на основе технологий инженерии знаний определены типы доступных данных, исходные и выходные данные, а также используемые необходимые знания.

Рис. 2. Формализация постановки задачи комплексной оценки пищевого поведения

3. Подход к решению задачи комплексной оценки пищевого поведения

Продолжая описывать этап концептуализации следует отметить, что процесс оценки пищевого поведения и формирования рекомендаций личности включает ряд подзадач общей задачи (рис. 3). В первую очередь необходимо оценить наличие или отсутствие проблемы лишнего веса у пользователя с помощью анализа индекса массы тела (ИМТ) и рассчитать оптимальное суточное количество килокалорий, белков, жиров и углеводов, необходимых человеку для эффективной борьбы с лишним весом. Эти расчеты производятся непосредственно при регистрации нового пользователя.

Следующим шагом является тестирование пользователя и выявление причин, являющихся существенными в формировании его пищевого поведения. Результатом, полученным на основе психологического (первый уровень) тестирования, станет отнесение пользователя к одному из 8 типов личности, для которых уже сформировано множество мотивационных

советов, рекомендаций и психологических методик, способных помочь пользователю эффективнее бороться с психологической составляющей проблемы.

Рис. 3. Декомпозиция задачи комплексной оценки пищевого поведения

Второй уровень тестирования – выявление недостатка витаминов, микроэлементов и аминокислот в организме и расчет оптимального набора продуктов питания с учетом полученных результатов, который поможет быстрее восполнить выявленный дефицит [Скальный, 2004], [Скальный, 2011].

Третий уровень – определение проблем пищевого поведения, таких как неправильный режим питания, проблемы сна, наличие вредных привычек и т.д. и формирование дополнительных критериев выборки советов для пользователя.

Также важным фактором является определение текущего эмоционального состояния, настроения и предложение пользователю дополнительного набора продуктов питания, которые помогут улучшить эмоциональное состояние, а значит избавить пользователя от вероятности переизбытка и срывов на фоне стресса или тревоги.

Выдвигается гипотеза, что факторы, которые оцениваются при проведении комплексной оценки пищевого поведения (рис. 4) формируются на основе: выборки советов и рекомендаций по типу личности, которые определяются после прохождения психологического теста СМИЛ, состоящего из 566 вопросов, 32 оценочных шкал; выборки советов о продуктах содержащих определенные гормоны для улучшения настроения на основе

теста настроения, включающих 5 базовых эмоций; выборки советов и рекомендаций для улучшения качества пищевого поведения на основе результатов поведенческого текста, включающего 10 дополнительных вопросов; выборки продуктов, содержащих необходимые витамины, минералы и аминокислоты на основе теста на выявление питательных веществ. Для предлагаемого программного решения характерным является сбор декларативных знаний о пациенте. Между понятиями предметной области определены отношения часть / целое, причина / следствие, иерархии (аспекты пищевого поведения и причины набора лишнего веса, требования к тестам и выбор специализированных тестов для оценки личности).



Рис. 4. Факторы влияния на комплексную оценку пищевого поведения

В итоге пользователь получает набор продуктов, советов и методик наиболее точно подходящий ему и с высокой долей вероятности способный эффективно бороться с лишним весом.

Комплексная оценка пищевого поведения включает следующие подзадачи: оценка наличия лишнего веса, расчет оптимальной суточной нормы килокалорий, белков, жиров и углеводов, трехуровневое тестирование пользователя и оценка настроения, формирование рациона питания, набор советов и рекомендаций.

Для определения нормы метаболизма (нормы килокалорий) была выбрана формула Харриса-Бенедикта [Большев и др., 2021], учитывающая максимальное число факторов личности и дающая оптимальный результат.

Расчет оптимальной суточной нормы килокалорий строится в зависимости от процентного соотношения суточной нормы БЖУ и цели расчета этой нормы, так для набора массы тела процентное соотношение выглядит следующим образом углеводы – 40-60%, белки – 25-35%, жиры – 15-25%; для поддержания веса: углеводы – 30-50%, белки – 25-35%, жиры – 25-35%; для похудения – углеводы – 10-20%, белки – 40-50%, жиры 30-40%.

С точки зрения технологии инженерии знаний наиболее интересными подзадачами выступают две последние. Так трехуровневое тестирование пользователя и оценка настроения основывается на психологическом тестировании; тестировании на определение недостатка витаминов, микроэлементов и питательных веществ в организме; тестировании на определение отклонений пищевого поведения.

Рассмотрим подробнее процедуру типирования личности на основе психологического тестирования. На основе основных проблем личности, способствующих набору веса, было выделено 8 типов личности, каждый из которых выделяется из показателей группы шкал теста СМИЛ [Собчик, 2000], [Собчик, 2005]. Типизация проводилась на основе работ психолога Л.М. Собчик и расшифровок анализа шкал [Собчик, 2005], [5da, 2022]. Фрагмент показателей шкал теста СМИЛ, соответствующие каждому из выявленных типов личности, а также описание типов личности представлены в табл. 2.

Так как 100% совпадение всех шкал в типах личности почти невозможно, было принято решение оценивать причастность тестируемого к тому или иному типу личности при попадании хотя в 70% (с округлением в большую сторону) рассматриваемых показателей.

Рассмотрим алгоритм определения типа личности на псевдокоде.

Дано: пусть T_i – рассчитанный показатель T -баллов пользователя по шкале i ; X_i – сумма сырых баллов пользователя по шкале i ; m_i – значение медианы для шкалы i ; σ_i – значение среднеквадратичного отклонения для шкалы i ; Δ_i – сумма весов попадания в диапазон заданных значений (табл. 2); N_j – норма значений веса для попадания в тип личности j (составляет 70% количества рассматриваемых шкал).

Таблица 2

Тип личности	Описание	Показатели шкал
Тип №1	Нормальная, гармоничная личность, не имеющая психологических проблем.	Шкала №1 – [0Т; 55Т] Шкала №2-3 – [50Т; 55Т] Шкала №4 – [0Т; 55Т] Шкала №6 – [45Т; 55Т] Шкала №7 < 55Т Шкала №8 < 60Т Шкала №9 < 95Т
Тип №2	Нормальная, адекватная личность, имеющая временные проблемы. Находится в состоянии временного стресса, депрессии, имеет проблемы в семье.	Шкала №2 > 65Т Шкала №51 > 55Т Шкалы №7 + №8 > 60Т (совместно)
....
Тип №8	Личность с неудовлетворенными потребностями	Шкала №4 \geq 60Т Шкалы №9, №58, №88, №189 > 55Т

Алгоритм для определения типа личности и рекомендация на псевдокоде выглядит следующим образом:

Для каждой шкалы i :

Рассчитать сумму «сырых» баллов X_i

Извлечь значение M_i

Извлечь значение δ_i .

$T_i =$ перевести «сырые» баллы в T -баллы по формуле $T = 50 + 10 * (X - M) / \delta$

Для каждого типа личности j :

ЕСЛИ попадает T_i в диапазон T для j ТО увеличить вес W_j

Для каждого j элемента массива весов:

ЕСЛИ $W_j \geq N_j$ ТО тип_личности = j

Для каждого значения T_i :

Сформировать строку выводов в соответствии с правилами вывода.

Рассмотрим пример правил вывода для типа личности №8:

ЕСЛИ ($T_4 \geq 60$) **ТО** ($W_8 = W_8 + 1$);

ЕСЛИ ($T_9 > 55$) **ТО** ($W_8 = W_8 + 1$);

ЕСЛИ ($T_{88} > 55$) **ТО** ($W_8 = W_8 + 1$);

ЕСЛИ ($T_{189} > 55$) **ТО** ($W_8 = W_8 + 1$);

ЕСЛИ ($W_4 \geq 4$) **ТО** тип_личности №8.

Фрагмент формирования строки выводов при анализе базовой шкалы №1 приведен далее. **ЕСЛИ ($T_4 < 45$) ТО** *"Ваше внимание обращено в основном на окружение. Вы довольно открытый активный человек с высокими возможностями к адаптации"*. **ЕСЛИ ($T_4 \geq 45$ И $T_4 \leq 47$) ТО** *"Вы практически не задумываетесь над состоянием своего здоровья или организма в связи с отсутствием каких-либо серьезных поводов к сомнению в них. Незагруженность сознания анализом своего состояния способствует вашей высокой активности, открытости, уверенности и высокой адаптативности"*. **ЕСЛИ ($T_4 \geq 48$ И $T_4 \leq 49$) ТО** *"Вы не склонны к фиксации внимания на ощущениях в своем организме или к жалобам на свое неудовлетворительное физическое состояние"*.

Следует отметить, что для данных решений использованы продукционные модели представления знаний.

Предложенный подход к комплексной оценке пищевого поведения был реализован в виде мобильного прототипа BestBody, которое включает следующие аспекты: психологическое тестирование пользователя, тестирование на выявление недостатка питательных веществ; тестирование на определение поведенческих факторов; формирование выборки из БД на основе типа личности пользователя; формирование рациона питания на основе результатов тестирования; анализ результатов тестирования.

Для разработки программного продукта были использованы: СУБД: SQLite; среда разработки БД: SQ Lite Browser 3.1, язык программирования: Java, среда разработки клиентской части: Android Studio 3.1. Фрагмент приложения представлен на рис. 5.

Для оценки работы предложенной методики разработанное приложение было установлено на мобильные устройства репрезентативной выборки потенциальных пользователей. Всего в исследовании принимали участие 300 человек. Пользователям предлагалось использовать приложение и его рекомендации в течение месяца и оценить эффективность методик, советов и выводов, предоставляемых приложением от 1 до 5. По результатам тестирования приложения на репрезентативной выборке пользователей были получены средние оценки: средняя оценка результатов психологического тестирования – 4.9; средняя оценка пользовательского интерфейса – 4.51; средняя оценка эффективности методик, советов и рекомендаций – 4.73.

Рис. 5. Фрагмент сценария работы приложения BestBody

Заключение

Вопросы управления пищевым поведением пациента затрагивают экспертные знания различных сфер, что обуславливает необходимость их извлечения, структуризации и формализации, и как следствие, использование технологий и методов инженерии знаний.

Для извлечения знаний использованы текстологические методы, универсальные методы и инструменты анализа текста на естественном языке.

Структурирование знаний позволило представить подход в виде комплексной оценки пищевого поведения, которая направлена на формирование выборки рекомендаций с учетом класса (тип личности). Классификация осуществляется на основе декларативных знаний о пациенте, собранных в результате прохождения человеком психологического теста СМИЛ (566 вопросов, 32 оценочных шкалы). Формализация знаний с использованием продукционных моделей, осуществляется с учетом знаний экспертов о продуктах, содержащих определенные виды гормонов, и обеспечивающих улучшение настроения по сравнению с результатами прохождения теста настроения, включающего пять базовых эмоций; об улучшении качества пищевого поведения на основе результатов поведенческого текста, включающего 10 дополнительных вопросов; о продуктах, содержащих необходимые витамины, минералы и аминокислоты на основе теста на выявление питательных веществ. Полученные результаты легли в основу разработанного мобильного приложения BestBody для операционной системы Android.

Список литературы

- [5da, 2022] Тест ММПИ(СМИЛ). [Электронный ресурс]. – URL: <http://www.5da.ru/analizsmil.html> (дата обращения: 14.09.2022).
- [Fatsecret, 2022] Счетчик Калорий и Трекер Диеты для потери веса. [Электронный ресурс]. – URL: <http://www.fatsecret.ru/>. (дата обращения: 18.09.2022).
- [Lifesum, 2022] Lifesum [Электронный ресурс]. – URL: <https://lifesum.com/> (дата обращения: 18.09.2022).
- [MyFitnessPal, 2022] MyFitnessPal. [Электронный ресурс]. – URL: <https://www.myfitnesspal.com/> (дата обращения: 18.09.2022).
- [Who, 2022] Всемирная Организация Здравоохранения [Электронный ресурс]. – URL: <http://www.who.int/> (дата обращения: 14.09.2022).
- [Большев и др., 2021] Большев А.С., Сидоров Д.Г., Овчинников С.А., Волкова И.В., Шукин В.М. Питание и физическая нагрузка. Методы расчета общего и физического метаболизма: учеб.-метод. пособие. Нижегород. гос. архитектур.-строит. ун-т: – Нижний Новгород: ННГАСУ, 2021. – 28 с.
- [Бройнинг, 2013] Бройнинг Л.Г. Гормоны счастья. Как приучить мозг вырабатывать серотонин, дофамин, эндорфин и окситоцин. – М.: Манн, Иванов и Фербер, 2016. – 320 с.
- [Бронникова, 2015] Бронникова С. Интуитивное питание: как перестать беспокоиться о еде и похудеть. Эксмо. – М.: 2015. – URL: http://www.litres.ru/pages/biblio_book?art=9524217 (дата обращения: 18.09.2022).
- [Васюткин, 2007] Васютин А.М. Психологическая диета или скажи «Нет» лишнему весу. – М.: Феникс, 2007. – 128 с.
- [Вербова и др., 2019] Вербовой А.Ф., Шаронова Л.А. Ожирение: эпидемиологические и социально-экономические аспекты, профилактика // Эндокринология: новости, мнения, обучение. – 2019. – Т. 8, № 3. – С. 87-97. – Doi: 10.24411/2304-9529-2019-13009.
- [Вознесенская, 2009] Вознесенская Т.Г. Расстройства пищевого поведения при ожирении и их коррекция. Клинический опыт // Фарматека. – 2009. – № 12. – С. 91-94. – URL: <https://lib.medvestnik.ru/apps/lib/assets/uploads/pharmateka/PDF/7570.pdf> (дата обращения: 18.09.2022).
- [Диета Онлайн, 2022] Диета Онлайн. [Электронный ресурс]. – URL: <http://www.dietaonline.ru/> (дата обращения: 18.09.2022).
- [Драпкина и др., 2021] Драпкина О.М., Самородская И.В., Старинская М.А., Ким О.Т., Неймарк А.Е. Ожирение: оценка и тактика ведения пациентов: коллективная монография. ФБУ «НМИЦ ТПМ» Минздрава России. – Изд-во ООО «Силиция-Полиграф. 2021. – 174 с.
- [Каримов и др., 2019] Каримов Т.К., Бермагамбетова С.К. Факторы, вызывающие ожирение и их алиментарная коррекция. [Электронный ресурс]. – URL: <https://cyberleninka.ru/article/n/factory-vyzyvayushchie-ozhirenie-iih-alimentarnaya-korreksiya/viewer> (дата обращения: 18.09.2022).
- [Колеман, 2013] Колеман Э. Питание для выносливости. – Мурманск: Тулома, 2005. – 192 с.
- [Мадкина-Пых, 2007] Малкина-Пых И.Г. Теория пищевого поведения: справочник практического психолога. – М.: Эксмо, 2007. – 1037 с.

- [**Скальный, 2004**] Скальный А. Микроэлементы для вашего здоровья. – Оникс 21 век, 2004. – 322 с.
- [**Скальный, 2011**] Скальный А. Микроэлементы. Бодрость, здоровье, долголетие. – Эксмо, 2011. – 288 с.
- [**Собчик, 2000**] Собчик Л. Н. Стандартизированный многофакторный метод исследования личности СМИЛ. – СПб.: Речь, 2000. – 219 с
- [**Собчик, 2005**] Собчик Л.Н. Стандартизированный многофакторный метод исследования личности СМИЛ (ММРІ) Практическое руководство. – М.: Речь, 2007. – 224 с
- [**Филиппов, 2013**] Филиппов И. Жир на кушетке. Взгляд психоаналитически ориентированного терапевта на проблему ожирения. – СПб.: БХВ Петербург, 2013. – 168 с
- [**Шведько, 2021**] Шведько А.В. Борьба с лишним весом: основные стратегии похудения. Science and Sport: Current Trends. – 2021. – No. 4 (Vol. 9). – URL: www.scienceandsport.ru (дата обращения: 18.09.2022).

УДК 004.89

**СОВРЕМЕННЫЕ АРХИТЕКТУРЫ
ИНТЕЛЛЕКТУАЛЬНЫХ ОБУЧАЮЩИХ СИСТЕМ
НА ОСНОВЕ ИНТЕГРИРОВАННЫХ ЭКСПЕРТНЫХ
СИСТЕМ: ОСОБЕННОСТИ ПОДХОДА
К АВТОМАТИЗИРОВАННОМУ ФОРМИРОВАНИЮ
ОНТОЛОГИЧЕСКОГО ПРОСТРАНСТВА ЗНАНИЙ
И УМЕНИЙ ОБУЧАЕМЫХ**

Г.В. Рыбина (*gvrybina@yandex.ru*)

А.А. Григорьев (*grigandal625@gmail.com*)

Национальный исследовательский ядерный университет «МИФИ»,
Москва

Анализируются особенности основных типов архитектур современных интеллектуальных обучающих систем (ИОС). Особое внимание уделяется ИОС на основе архитектур обучающих интегрированных экспертных систем (ИЭС) и обучающих веб-ИЭС, базовые принципы и технология разработки которых определяются задачей ориентированной методологией построения ИЭС и средствами инструментального комплекса АТ-ТЕХНОЛОГИЯ. Обсуждаются предпосылки, полученные результаты и дальнейшие перспективы автоматизированного формирования единого онтологического пространства знаний и умений обучаемых путем использования обучающих веб-ИЭС на всем цикле обучения.

Ключевые слова: интеллектуальные обучающие системы (ИОС), обучающие интегрированные экспертные системы, обучающие ИЭС), веб-ИЭС, задачно-ориентированная методология, интеллектуальное обучение, модель обучаемого, модель онтологии, онтологическое пространство, мониторинг, знания, умения.

Введение

В настоящее время перспективные отечественные и зарубежные исследования в области компьютерных образовательных технологий связаны с созданием различных средств интеллектуального компьютерного обучения на основе разработки и использования интеллектуальных обу-

чающих систем (ИОС), интегрирующих все многообразие методов и средств искусственного интеллекта (ИИ) с методами и подходами из других областей, в частности, педагогики и психологии [Галеев, 2010], [Рыбина, 2010], [Рыбина, 2014], [Sosnovsky at all, 2008], [Bonner at all, 2015], [Nye, 2015], [Rahman at all, 2016] и др.

Архитектуры современных ИОС ориентированы на поддержку решения задач интеллектуального обучения, в основе которого заложена концептуальная и логическая взаимосвязь процессов *индивидуализации*, *веб-ориентации* и *интеллектуализации* [Рыбина, 2014], поэтому все методы и подходы к проектированию ИОС с различной архитектурной типологией должны удовлетворять этим целям. Однако, используя популярность данной проблемы, сегодня наблюдается процесс «зашумления» самого понятия ИОС, поскольку достаточно часто под видом ИОС описывается большое количество компьютеризированных курсов и систем электронного обучения по различным предметам и дисциплинам, включая системы дистанционного электронного обучения и создание многочисленных коммерческих курсов и программ.

Исторические рамки зарождения и становления проблематики ИОС обычно соотносят с периодом 1970-1980-х гг. и связывают с именами Дж. Карбонелла [Carbonell, 1970], а затем П.Л. Брусиловского [Брусиловский, 1990], которыми было сформулировано общее представление об ИОС как особом классе прикладных интеллектуальных систем, в архитектурах которых предусмотрена возможность автоматизированной поддержки не только моделей проблемных областей (ПрО), но и *моделей обучаемых* и *разнообразных моделей обучения*. Основными целями создания ИОС являлись: разработка и развитие адаптивной обучающей среды; организация диагностического процесса выявления ошибок в знаниях и умениях обучаемых; формирование персонифицированной обучающей стратегии в соответствии с текущей ситуацией в процессе обучения и т.п.

Различные классификации ИОС и подходы к их разработке стали активно предлагаться уже в конце 1980-х гг., а начиная с 2000-х гг. получили наибольшее развитие, исходя из многообразия архитектур ИОС и состояния текущей технологической базы, определяемой возможностями интернета, обучения через веб, дистанционными технологиями, облачными вычислениями и др. средствами. Общему анализу ИОС раннего периода и эволюции основных парадигм разработки ИОС посвящены работы [Брусиловский, 1990], [Петрушин, 1993], [Tang at all, 2000], [Galeev at all, 2000], [Брусиловский, 2002], [Стефанюк, 2002], [Голенков и др., 2001], [Sosnovsky at all, 2008], [Рыбина, 2014] и др.

Рассмотрим примеры некоторых характерных подходов к построению современных архитектур ИОС, (не претендуя на исчерпывающую полноту анализа всех типов архитектур ИОС), а затем в контексте данной работы сфокусируем внимание на особенностях конкретного класса ИОС – обучающих интегрированных экспертных системах (ИЭС) и веб-ИЭС.

1. Общая характеристика архитектур ИОС и инструментальных средств для их разработки

С точки зрения архитектуры, состава и структуры основных компонентов и средств ИОС, к настоящему времени исторически сформировалось несколько типов базовых архитектур ИОС: проблемно-специализированные ИОС с акцентом на специфику Про обучения (в частности, на основе экспертных систем (ЭС) и экспертно-обучающих систем); веб-ориентированные ИОС (веб-ИОС), веб-ориентированные обучающие адаптивные системы (веб-ОАС); обучающие интегрированные экспертные системы (ИЭС) и веб-ИЭС как полнофункциональные классы ИОС; агентно-ориентированные ИОС и ИОС на основе различных архитектур многоагентных систем (МАС); ИОС на основе технологий облачных платформ.

Архитектуры проблемно-специализированных ИОС на основе ЭС, а также веб-ИОС и веб-ОАС не являются полностью новыми или уникальными, поскольку в соответствии с требованиями к ИОС здесь в основном используются знания о специфике Про обучения, об обучаемом и стратегиях обучения для поддержки персонализированного процесса изучения конкретных дисциплин. Наибольшим архитектурным разнообразием отличаются агентно-ориентированные ИОС [Rah an at all, 2016], в состав архитектуры которых входят, например, следующие типы агентов: агенты интерфейса преподавателя, агент интерфейса обучения, агент доступа к знаниям, агент онтологий, агент-координатор взаимодействий между агентами и др.

Предлагается целый ряд ИОС, в которых агенты, например, кафедры ВУЗа [Алешенко и др., 2016] создаются с учетом требований сервисно-ориентированной архитектуры, основными компонентами которой являются: репозиторий учебных объектов; агент обучаемого; оценка знаний обучаемого; формирование индивидуальных программ обучения; персональная среда обучения; методическая поддержка и др. В других ИОС [Тельнов и др., 2016] получил распространение сервисно-компонентный подход к архитектуре системы с целью обеспечения доступности и автономности компонентов. Прототип МАС сетевого взаимодействия учебных заведений описан в [Тельнов и др., 2018].

В области создания инструментальных средств (ИС) поддержки разработки ИОС и веб-ИОС не наблюдается значительных новаций, поскольку основное внимание уделяется реинжинирингу и дальнейшему развитию существующего инструментария. В качестве примера можно привести семейство ИС типа МОНАП [Галеев, 2010], на основе которых реализован ряд прикладных ИОС, например, в [Аляутдинова и др., 2017] описан пример использования веб-версии МОНАП, с помощью которой педагоги-предметники из однотипных ПрО могут создавать свои среды обучения с различными дидактическими характеристиками.

Современными возможностями для реализации ИОС обладает платформа IASaaS [Грибова и др., 2011] для поддержки разработки, управления и удаленного использования прикладных и системных многоагентных облачных сервисов (включая интеллектуальные) и их компонентов. Имеется опыт создания на основе IASaaS нескольких ИОС для медицинских ПрО [Грибова и др., 2016].

Большие перспективы интеллектуального обучения показали обучающие ИЭС и веб-ИЭС, которые с 2008г. активно используются для поддержки образовательного процесса в НИЯУ МИФИ, постоянно совершенствуясь и развиваясь. Обучающие ИЭС, разработанные на основе единой задачно-ориентированной методологии построения ИЭС [Рыбина, 2008] и поддерживающего ее инструментария – комплекса АТ-ТЕХНОЛОГИЯ [Рыбина, 2008],[Рыбина и др., 2018], являются полнофункциональными ИОС, поскольку, наследуя фундаментальные принципы моделирования ПрО от традиционных ИЭС, обладают кроме того масштабируемой архитектурой, позволяющей расширять функциональность ИЭС с помощью дополнительных подсистем, обеспечивающих характерные для ИОС процессы построения моделей обучаемых, моделей обучения, моделей объяснения и др. средств.

В качестве базовых архитектурных решений, используемых для обучающих веб-ИЭС, следует выделить: разработку средств, поддерживающих веб-тестирование обучаемых для выявления текущего уровня *знаний* обучаемых на основе прикладных онтологий курсов-дисциплин; организацию веб-взаимодействия с программными компонентами, обеспечивающих выявление уровня *умений* обучаемых решать неформализованные задачи (НФ-задачи) [Рыбина и др., 2015], [Рыбина, 2017]; разработку адаптивной обучающей программной среды на основе семантической интеграции взаимодействующих процессов построения индивидуальных моделей обучаемых и обучения в контексте реализации конкретной учебной программы или онтологии образовательной деятельности [Рыбина, 2017].

Постоянно усовершенствуется и экспериментально исследуется на практике созданный для автоматизированной поддержки данной методологии специальный инструментарий типа Workben h (комплекс АТ-ТЕХНОЛОГИЯ), на базовой функциональной платформе которого уже создано несколько поколений ИС, обеспечивающих в том числе и *интеллектуальную* поддержку процессов разработки и сопровождения прикладных ИЭС на всех этапах жизненного цикла [Рыбина и др. 18], [Rybina at all, 2021].

В настоящее время важное место в исследованиях и разработках, связанных с решением задач интеллектуального обучения с использованием обучающих веб-ИЭС, принадлежит онтологическому инжинирингу, что позволило реализовать общую концепцию *единого онтологического пространства знаний и умений обучаемых* и на основе средств интеллектуальной программной среды комплекса АТ-ТЕХНОЛОГИЯ провести цикл исследований по автоматизированному формированию единого онтологического пространства знаний и умений обучаемых на всем цикле обучения, с целью построения компетентностно-ориентированных моделей выпускников по конкретным направлениям подготовки [Rybina at all, 2022].

Рассмотрим кратко имеющийся опыт использования онтологий в современных ИОС для реализации указанных целей, акцентируя внимание только на образовательной сфере.

2. Место и роль онтологий в интеллектуальном обучении на основе использования ИОС в образовательной сфере

Построение и активное использование онтологий является важной особенностью развития современных информационных систем с разнообразной архитектурной типологией, включая прикладные интеллектуальные системы типа ИОС, причем число предлагаемых моделей, методов, способов, специальных языков, ИС и платформ уже зашкаливает (детальные обзоры приводятся в [Гаврилова, 2016],[Рыбина и др., 2017]). В зависимости от выбранных критериев. существуют многочисленные классификации онтологий, наиболее известная из которых – классификация Н. Гуарино (N. Guarino) и Д.Фензел (D.Fensel), основанная на уровнях общности онтологических моделей и выделением онтологий верхнего уровня, онтологий предметных областей (доменных), онтологий представления знаний и прикладных онтологий.

Одним из наиболее распространенных направлений использования онтологий является образовательный процесс, однако, сфера применения онтологий здесь связана, в основном, с автоматизированными информационными системами и традиционными компьютерными обучающими

системами. Используя [Рыбина и др., 2017] и [Rybina at all, 2022], рассмотрим некоторые характерные примеры, позиционируя роль онтологий в реализации различных архитектур ИОС.

Интересными перспективами, особенно в контексте данной работы, обладает проект создания информационно-образовательного пространства [Тельнов и др., 2016], в котором важное место отводится онтологиям разного типа: онтологии предметной области (создается семантика учебных объектов); онтологии учебных объектов (обеспечивается управление учебным контентом); онтологии компетенций (выстраивается последовательность изучения учебных материалов).

Вариант использования онтологического подхода при создании распределенных ИОС, базирующихся на технологии МАС и принципах проекта Semantic Web, был предложен, например, в [Келеберда и др., 2004] как развитие систем дистанционного обучения. С точки зрения ИОС персонализация в обучении достигается за счет онтологических моделей, которые являются метазнаниями для осуществления индивидуального подбора обучаемому учебных материалов и кодируются на специализированном языке OWL.

В целом, типология используемых в ИОС онтологий для учебного процесса определяется прикладными онтологиями и онтологиями предметной области. В отечественной практике чаще всего применяются прикладные онтологии различных учебных курсов/дисциплин, для чего предложено много различных подходов – от методов визуального структурирования информации до методологии управления знаниями для интеграции разработки множества учебных курсов на кафедральном и межкафедральном уровнях [Алещенко и др., 2016]. В работе [Грибова и др., 2016] описана интеллектуальная обучающая среда для диагностики острых и хронических заболеваний, в которой используется несколько типов предметных онтологий.

Достаточно активно в ИОС используются онтологические представления моделей обучаемых, базируясь исключительно на отражении уровня знаний обучаемого. Например, в [Кучер и др., 2010] описана онтологическая модель обучаемого, на основе которой строится индивидуальная траектория обучения, а онтологическая модель обучаемого в [Топоркова, 2009] отражает не только структуру, но и динамику формирования профессиональных знаний. Существует также целый ряд работ по ИОС, в которых рассматривается онтологический подход к созданию моделей обучения и систем управления обучением, например, [Conati, 2012], [Stancheva at all, 2016] и др.

Однако, даже в самых развитых архитектурах ИОС в основном рассматриваются модели обучаемых, отражающие только уровни усвоения декларативных *знаний* по конкретным учебным дисциплинам или приобретенные компетенции, и мало уделяется внимания вопросам выявления процедурных знаний, т.е. *навыков/умений* применять полученные знания на практике.

Кроме того, анализ различных архитектур ИОС в контексте использования онтологического подхода показал, что в настоящее время, практически, отсутствуют методы и средства, обеспечивающие реализацию автоматизированного построения и практического использования единого онтологического пространства знаний и умений обучаемых, формируемого на протяжении всего образовательного цикла по конкретным направлениям/ специальности подготовки выпускников.

Теперь рассмотрим кратко основные подходы и особенности реализации базовой концепции автоматизированного формирования онтологического пространства знаний и умений обучаемых на основе комплекса моделей и программных средств поддержки построения обучающих веб-ИЭС.

3. Особенности построения моделей обучаемых на основе прикладных онтологий курсов/дисциплин

Методический и технологический опыт использования в учебном процессе, поддерживаемом *обобщенной* онтологией «Интеллектуальные системы и технологии» и текущими версиями обучающих веб-ИЭС, позволил к настоящему времени реализовать, практически, полный набор типовых задач интеллектуального обучения, концептуально и формально позиционированных еще в ранних исследованиях, в частности [Рыбина, 2010], а затем конкретизированных по результатам экспериментального программного моделирования и апробации в реальных условиях учебного процесса в НИЯУ МИФИ [Рыбина, 2017], а именно: *индивидуальное планирование методики изучения учебных курсов/дисциплин* (конкретизация для каждого обучаемого последовательности тем/разделов курса, индивидуальный контроль и выявление «проблемных зон» и уровней текущих компетенций обучаемых, оптимизация индивидуального обучения с учетом личностных характеристик обучаемых); *интеллектуальный анализ решений учебных задач* (моделирование рассуждений студентов, решающих НФ-задачи, выявление и классификация типов ошибок и пробелов в знаниях вместо их констатации, обратная связь через динамическое обновление знаний обучаемых); *интеллектуальная поддержка принятия решений в контексте реализации функциональности традиционных ЭС* (интеллектуальная помощь на каждом этапе решения учебных задач, объяснения типа "как?" и "почему?", подсказка следующего этапа решения).

Ведущая роль в реализации вышеперечисленных задач принадлежит прикладным онтологиям курсов/дисциплин для построения текущих моделей обучаемых путем применения онтологий при организации процессов выявления *знаний* и *умений* обучаемых, осуществляемых в режиме RunTime (предназначен для обучаемого) в рамках проведения контрольных мероприятий в виде веб-тестирований и т.п.

Выявление *знаний* обучаемых производится на основе использования созданных в режиме DesignTime (предназначен для преподавателя) прикладных онтологий курсов/дисциплин и динамического формирования текущих компетентностно-ориентированных моделей обучаемых, которые строятся на основе анализа ответов на вопросы из специальных веб-тестов, диагностики пробелов в знаниях (обнаружение так называемых «проблемных зон» и текущих компетенций путем сравнения с фрагментами онтологий) и последующего формирования индивидуальных планов или стратегий обучения с использованием различных типов конкретных обучающих воздействий. Генерация вариантов тестовых заданий осуществляется перед началом веб-тестирования путем применения генетического алгоритма [Рыбина, 2014] к заданному фрагменту прикладной онтологии курса/дисциплины.

Процессы выявления *умений*, выполняемые также в режиме RunTime, несут более специализированный характер и определяются реализованными на текущий момент моделями навыков/умений решать конкретные типы НФ-задач по конкретному курсу/дисциплине и возможностями программной поддержки взаимодействия с элементами (вершинами) соответствующих прикладных онтологий (данные вопросы детально рассматриваются в [Рыбина и др., 2015]).

Таким образом, общее понятие онтологического пространства знаний и умений обучаемых с позиции архитектуры обучающих веб-ИЭС может трактоваться как совокупность всех информационно-образовательных процессов и ресурсов по реализации типовых задач интеллектуального обучения в течение полного цикла непрерывного обучения на основе обобщенной онтологии и средств интеллектуальной программной среды комплекса АТ-ТЕХНОЛОГИЯ, с целью автоматизированного построения компетентностно-ориентированных моделей выпускников по конкретным направлениям подготовки. В этом случае автоматизированное формирования онтологического пространства знаний и умений обучаемых представляет собой по сути полнофункциональный *образовательный мониторинг* функционирования обучающих веб-ИЭС в течение полного цикла обучения (рассматривается в 5.).

4. Базовая модель онтологии и особенности автоматизированного формирования онтологического пространства знаний и умений обучаемых

Вопросы, связанные с разработкой моделей, методов и ИС поддержки построения онтологий на основе задачно-ориентированной методологии и средств комплекса АТ-ТЕХНОЛОГИЯ рассматривались в целом ряде работ, в частности, [Рыбина, 2014], [Рыбина, 2017], [Rybina et al., 2022] и др. Поэтому здесь выделим только наиболее важные свойства и особенности, позиционирующие место, роль и возможности предложенного онтологического подхода в развитии интеллектуального обучения на основе использования обучающих веб-ИЭС.

1. Обеспечивается общая методическая и программная поддержка всех процессов построения прикладных онтологий курсов/дисциплин и обобщенных онтологий специальностей/направлений подготовки на основе единой *модели онтологии* в виде семантической сети специального типа (формальные аспекты описаны в [Рыбина, 2014], [Рыбина, 2017] и др. работах).

2. В отличие от моделей онтологий, использующихся в большинстве компьютерных обучающих систем и ИОС, предложенная модель обеспечивает: широкие возможности представления в качестве элементов семантической сети (вершин сети) не только понятий, относящихся к иерархической структуре курсов/дисциплин (разделы, темы, подтемы и т.п.), но и различных моделей компетенций, а также моделей обучающих воздействий и моделей выявления навыков/умений обучаемых [Рыбина и др., 2017]; возможность отображения различных типов отношений между вершинами сети не только таксономического типа, но и семантических отношений, отражающих специфику взаимосвязей всех элементов модели онтологии; развитую алгоритмическую и поддержку для реализации требуемой функциональности при интерпретации разнородных элементов модели онтологии.

3. Все процессы построения прикладных и обобщенных онтологий на основе базовой модели онтологии осуществляются в автоматизированном режиме за счет разработки специализированных ИС, оформленных в соответствии с требованиями интеллектуальной программной среды комплекса АТ-ТЕХНОЛОГИЯ в качестве повторно-используемых компонентов.

4. С точки зрения архитектуры обучающих ИЭС и веб-ИЭС, предложенный онтологический подход универсален, поскольку применяется не только для построения прикладных онтологий курсов/дисциплин, но и выполняет важную алгоритмическую и технологическую функцию при построении компетентностно-ориентированных моделей обучаемых и адаптивных моделей обучения.

5. Концептуальные и интеграционные возможности базовой модели онтологии позволяют решать взаимосвязанные комплексные задачи автоматизированного формирования единого онтологического пространства знаний и умений обучаемых [Rybina at all, 2022] в условиях как *интеллектуализации* процессов разработки прикладных ИЭС в целом [Rybina at all, 2021], так и в контексте дальнейшего развития технологии интеллектуального обучения на основе обучающих веб-ИЭС, что достигается использованием: совокупности моделей, отражающих большой экспертный и технологический опыт создания уникальных методик, процедур, алгоритмов и средств выявления и оценивания умений обучаемых решать НФ-задачи, предусмотренные в рамках обобщенной онтологии как типовые задачи интеллектуального обучения; совокупности реализованных на текущий момент обучающих воздействий различного типа, из которых формируются затем конкретные планы (стратегии) обучения (детально описаны в [Рыбина, 2014] и др. работах).

Рассмотрим некоторые методические и технологические особенности мониторинга процессов функционирования обучающих веб-ИЭС.

5. Разработка средств мониторинга процессов функционирования обучающих веб-ИЭС и методов обработки его результатов

Традиционный взгляд на проблему мониторинга любой автоматизированной системы, включая образовательный мониторинг, предполагает создание системы сбора, хранения, анализа и представления информации о состоянии наблюдаемых объектов, явлений и процессов с целью их оценки, контроля или прогноза. В данном случае мониторинг функционирования обучающей веб-ИЭС определяется технологией реализации набора функциональных задач, характерных для интеллектуального обучения, и в целом связан с «отслеживанием» и анализом всех процессов построения для каждого студента индивидуальной компетентностно-ориентированной модели обучаемого по соответствующей дисциплине (путем выявления текущего уровня знаний/умений) и динамического формирования соответствующей модели обучения.

В настоящее время удалось обеспечить выполнение большинства требований образовательного мониторинга за счет автоматизации, практически, всех процессов, возникающих в ходе обучения и контроля знаний/умений обучаемых. При этом вся информация об обучаемых, темах курсов/дисциплин, результатах прохождения обучения, результатах контроля обучаемых и индивидуальных рекомендациях находится в единой онтологической среде и в любое время доступна обучаемому и/или контролирующему процесс обучения. Управление, анализ и обработка теку-

щих результатов мониторинга обеспечивается за счет разработки специальных средств интеллектуальной программной среды комплекса АТ-ТЕХНОЛОГИЯ.

Среди основных требований к методам и алгоритмам обработки результатов мониторинга следует указать: необходимость постоянного формирования контингентов обучаемых с высокими и/или низкими показателями уровня знаний/умений и компетенций; проведение систематической аналитико-статистической обработки данных на основе введенных параметров; генерация текущих и итоговых отчетов (ведомостей) для кафедр и других подразделений вуза, отражающих компетентностно-ориентированные модели обучаемых, а также дополнительные сведения о самостоятельной работе, прогноз итоговой оценки и др. информацию.

Для проведения аналитико-статистической обработки результатов мониторинга были предложены базовые параметры, включающие: анализ «проблемных зон» обучаемых и их кластеризация; анализ эффективности применения индивидуального плана обучения путем оценки влияния обучающих воздействий на повышение уровня знаний и определения наиболее подходящих обучающих воздействий; расчет корреляции между уровнем умений и уровнем знаний по соответствующим темам курса/дисциплины и др. Для большинства из этих параметров разработаны соответствующие методы, алгоритмы и специальные программные средства, другие, более сложные, находятся в стадии предварительного исследования и будут уточняться.

При мониторинге процессов функционирования обучающихся ИЭС необходимо учитывать такие факторы как требования к надежности и безопасности обучающихся ИЭС и веб-ИЭС, а также обеспечивать контроль авторских прав экспертов (преподавателей-предметников) на знания и умения, формализованные в ходе разработки каждой конкретной прикладной онтологии курса/дисциплины.

Заключение

Общее понятие единого онтологического пространства знаний и умений обучаемых как адаптивной программной среды интеллектуального обучения на основе использования обучающих веб-ИЭС, сформировалось исходя из развития базовых положений задачно-ориентированной методологии построения ИЭС, изначально ориентированных на мощные интеграционные возможности при моделировании типовых архитектур ИЭС.

С другой стороны, опыт использования обучающих ИЭС и веб-ИЭС в условиях реального учебного процесса позволил разработать оригинальные подходы и методы выявления как текущего уровня знаний обучаемых, так и умений/навыков обучаемых решать различные учебные задачи,

в том числе НФ-задачи. Накопление методического опыта в виде широкого спектра реализованных обучающих воздействий различной типологии обеспечило возможность динамического построения в рамках единой онтологической среды индивидуальных стратегий (планов) обучения с учетом диагностированных «проблемных зон» обучаемых.

В перспективе, с точки зрения поддержки полного образовательного цикла и формирования итоговых компетентностно-ориентированных моделей выпускников, необходимо значительно усилить интеграционную роль обобщенной онтологии, а также расширить алгоритмическую и программную базу для реализации образовательного мониторинга процессов функционирования обучающих веб-ИЭС.

Список литературы

- [Алещенко и др., 2016] Алещенко А.С., Трембач В.М. Интеллектуальная обучающая система кафедры ВУЗа // Открытое образование. – 2016. – №5.
- [Аляутдинова и др., 2017] Аляутдинова Г.Р., Игнарица Е.С., Пайгина Л.Р. Организация процесса обучения с помощью интеллектуальной обучающей системы МОНАП//ОТО. – 2017. – № 3.
- [Брусиловский, 2002] Брусиловский П.Л. Адаптивные и интеллектуальные технологии в сетевом обучении // Новости искусственного интеллекта. – 2002. – № 5.
- [Брусиловский, 1990] Брусиловский П.Л. Интеллектуальные обучающие системы // Информатика. Информационные технологии. Средства и системы. – 1990. – № 2.
- [Галеев, 2010] Галеев И.Х. Модель управления процессом обучения в ИОС//Международный электронный журнал «Образовательные технологии и общество». – 2010. – Т. 13.
- [Гаврилова, 2016] Гаврилова Т.А. Инженерия знаний. Модели и методы: учебник. – СПб.: Изд-во «Лань», 2016.
- [Голенков и др., 2001] Голенков В.В., Гулякина Н.А., Тарасов В.Б., Елисеева О.Е. и др. Интеллектуальные обучающие системы и виртуальные учебные организации. – Мн.: БГУИР, 2001.
- [Грибова и др., 2011] Грибова В.В., Клещев А.С., Крылов Д.А., Москаленко Ф.М. и др. Проект IASPaas. Комплекс для интеллектуальных систем на основе облачных вычислений // Искусственный интеллект и принятие решений. – 2011. – № 1.
- [Грибова и др., 2016] Грибова В.В., Островский Г.Е. Интеллектуальная обучающая среда для диагностики острых хронических заболеваний // Пятнадцатая национальная конференция по искусственному интеллекту с международным участием КИИ-2016: Труды конференции. Т. 3. – Смоленск: Универсум, 2016.
- [Келеберда и др., 2004] Келеберда И.Н., Лесная Н.С., Репка В.Б. Использование мультиагентного онтологического подхода к созданию распределенных систем дистанционного обучения // Образовательные технологии общества. – 2004. – Т. 7, № 2.

- [**Кучер и др., 2010**] Кучер А.В., Сокол В.В., Лесная Н.С., Бочаров А.В. Архитектура системы построения индивидуальной траектории обучения, базирующейся на образовательном стандарте // Проблемы высшей школы. – 2010. – № 2 (38).
- [**Петрушин, 1993**] Петрушин В.А. Обучающие системы: архитектура и методы реализации (обзор) // Известия РАН. Техническая кибернетика. – 1993. – № 2.
- [**Рыбина, 2008**] Рыбина Г.В. Теория и технология построения интегрированных экспертных систем: монография. – М.: Изд-во «Научтехлитиздат», 2008.
- [**Рыбина, 2010**] Рыбина Г.В. Современные подходы к реализации интеллектуального компьютерного обучения на основе разработки и использования обучающих интегрированных экспертных систем // Приборы и системы. Управление, Контроль, Диагностика. – 2010. – № 5.
- [**Рыбина, 2014**] Рыбина Г.В. Интеллектуальные системы: от А до Я: Серия монографий в трех книгах. Кн.1. Системы, основанные на знаниях. Интегрированные экспертные системы. – М.: Научтехлитиздат, 2014.
- [**Рыбина, 2017**] Рыбина Г.В. Интеллектуальная технология построения обучающих интегрированных экспертных систем: новые возможности // Открытое образование. – 2017. – Т. 21, № 4.
- [**Рыбина и др., 2015**] Рыбина Г.В., Сергиенко Е.С. Интеллектуальное обучение на основе интегрированных экспертных систем: моделирование умений обучаемых решать сложные учебные задачи // Информационно-измерительные и управляющие системы. – 2015. – № 1.
- [**Рыбина и др., 2017**] Рыбина Г.В., Сергиенко Е.С., Сорокин И.А., Белова А.С., Бочкова Т.В. Онтологический подход к организации учебного процесса на основе разработки и использования обучающих интегрированных экспертных систем // Приборы и системы. Управление, Контроль, Диагностика. – 2017. – № 2.
- [**Рыбина и др., 2018**] Рыбина Г.В., Блохин Ю.М., Фонталина Е.С., Сорокин И.А., Таракчан Л.С. Интеллектуальная программная среда комплекса АТ-ТЕХНОЛОГИЯ: некоторые аспекты применения для построения интегрированных экспертных систем // Информационно-измерительные и управляющие системы. – 2018. – № 8.
- [**Стефанюк, 2002**] Стефанюк В.Л. Введение в интеллектуальные обучающие системы: учебно-методическое пособие. – М.: Изд-во РУДН, 2002.
- [**Тельнов и др., 2016**] Тельнов Ю.Ф., Казаков В.А. Онтологическое моделирование сетевых взаимодействий организаций в информационно-образовательном пространстве // XV национальная конференция по искусственному интеллекту с международным участием КИИ-2016: Труды конференции. В 3-х т. Т. 1. – Смоленск: Универсум, 2016.
- [**Тельнов и др., 2018**] Тельнов Ю.Ф., Данилов А.В., Дивеев Р.И., Казаков В.А., Ярошенко Е.В. Разработка прототипа многоагентной системы сетевого взаимодействия учебных заведений. // Открытое образование. – 2018. – Т. 22, № 6.
- [**Топоркова, 2009**] Топоркова О.М. Семиотико-онтологическая модель обучения как концептуальная основа организации учебного процесса // Прикладная информатика. – 2009. – № 4.
- [**Carbonell, 1970**] Carbonell J.R. AI in CAI: An artificial intelligence approach to computer-assisted instruction // IEEE Transactions on Man-Machine Systems. – 1970. – Vol. MMS-11, No. 4.

- [**Bonner at all, 2015**] Bonner D., Walton J., Dorneich M.C., Gilbert S.B., Winer E., Sottolare R.A. The development of a testbed to assess an intelligent tutoring system for teams // Workshops at the 17th International Conference on Artificial Intelligence in Education, AIED-WS 2015; CEUR Workshop Proceedings. – 2015.
- [**Conati, 2012**] Conati C. Student modeling and intelligent tutoring beyond coached problem solving // Adaptive Technologies for Training and Education. – 2012.
- [**Galeev at all, 2000**] Galeev I.K., Chepegin V.I., Sosnovsky S.A. MONAP: Models, Methods and Applications // Proceedings of the International Conference KBCS 2000. Mumbai, India, 2000.
- [**Tang at all, 2000**] Tang, T.Y., Wu, A. The implementation of a multi-agent intelligent tutoring system for the learning of computer programming // Proceedings of 16th IFIP World Computer Congress-International Conference on Educational Uses of Communication and Information Technology. (ICEUT). – 2000.
- [**Nye, 2015**] Nye B.D. Intelligent tutoring systems by and for the developing world: A review of trends and approaches for educational technology in a global context // International Journal of Artificial Intelligence in Education. – 2015. No. 25.
- [**Rahman at all, 2016**] Rahman A.A., Abdullah M., Alias S.H. The architecture of agent-based intelligent tutoring system for the learning of software engineering function point metrics // 2nd International Symposium on Agent, Multi-Agent Systems and Robotics, ISAMSR 2016. – 2016.
- [**Rybina at all, 2021**] Rybina G., Slinkov A. The Implementation of the Ontological Approach to Control of the Processes of Designing Integrated Expert Systems Based on the Problem-Oriented Methodology // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2021, 12948 LNAI.
- [**Rybina at all, 2022**] Rybina G.V., Nikiforov A.Y., Slinkov A.A. and Grigoryev A.A. Automated Formation of the Unified Ontological Base of Students' Knowledge and Skills to Implement Intellectual Tutoring Tasks Based on Tutoring Integrated Expert Systems // 2022 VI International Conference on Information Technologies in Engineering Education (Inforino). – 2022.
- [**Sosnovsky at all, 2008**] Sosnovsky S., Mitrovic A., Lee D., Brusilovsky P., Yudelson M. Ontology-based integration of adaptive educational systems // In: 16th International Conference on Computers in Education (ICCE 2008). – 2008.
- [**Stancheva at all, 2016**] Stancheva N., Stoyanova-Doycheva A., Popchev I., Stoyanov S. Automatic generation of test questions by software agents using ontologies // Proc. of IEEE 8th International Conference on Intelligent Systems. Sofia, Bulgaria. 2016.

ИССЛЕДОВАНИЕ ВОЗМОЖНОСТЕЙ ВЫЯВЛЕНИЯ АНОМАЛЬНОГО ПОВЕДЕНИЯ ПОЛЬЗОВАТЕЛЕЙ ЦЕНТРОВ ОБРАБОТКИ ДАННЫХ НА ОСНОВЕ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ*

И.Б. Саенко (*ibsaen@comsec.spb.ru*)

И.В. Котенко (*ivkote@comsec.spb.ru*)

Санкт-Петербургский Федеральный исследовательский центр РАН,
Санкт-Петербург

М.Х. Аль-Барри (*mazenb51@gmail.com*)

Военная академия связи, Санкт-Петербург

В работе описываются основные положения предлагаемого метода выявления аномального поведения пользователей центров обработки данных, в котором используются модели машинного обучения. Рассматриваются вопросы, связанные с формированием признакового пространства для моделей машинного обучения, программной реализацией и экспериментальной оценкой предлагаемого метода.

Ключевые слова: прикладные интеллектуальные системы, обнаружение аномалий, центр обработки данных, машинное обучение, кибербезопасность.

Введение

Центры обработки данных (ЦОД) являются сложными информационно-телекоммуникационным объектами, предназначенными для хранения и обработки информации в интересах управления критическими системами [Воронцов и др., 2020]. Они предполагают коллективное использование хранимых данных. В настоящее время ЦОД завоевывают все большую популярность во многих областях деятельности человека, включая промышленность [Мочалов и др., 2020], транспорт [Ефремов, 2022], банковский сектор [Маматов, 2021], здравоохранение [Чешейко, 2021], науку и образование [Мартышкин, 2022] и другие сферы. Высокая критическая

* Работа выполнена при финансовой поддержке РФФИ в Санкт-Петербургском Федеральном исследовательском центре РАН (проект № 21-71-20078).

значимость ЦОД остро поднимает вопросы обеспечения их безопасности [Касенова, 2021]. Эти объекты могут иметь достаточно большое количество угроз компьютерной безопасности, как внешних, так и внутренних [Белянская и др., 2021]. Чтобы противодействовать внешним угрозам, ЦОД оснащаются множеством средств защиты, таких как антивирусные средства, межсетевые экраны, системы мониторинга и т.д. [Котенко, 2014; Асадуллин, 2020]. Однако противодействие внутренним угрозам, которые вызваны, в частности, аномальным поведением пользователей ЦОД, является проблемой, которая еще находится в стадии своего решения.

Поведение пользователей ЦОД определяется запросами, с которыми они обращаются к базам данных центра. Эти запросы могут нести две основные угрозы компьютерной безопасности: атаки вида SQL-инъекции (к запросу пристраивается некоторый вредоносный код) и несанкционированный доступ (НСД) к таблицам данных (пользователи обращаются к запрещенным данным). В первом случае известен ряд методов выявления SQL-инъекций [Marashdeh et al., 2021]. Однако большинство из них используют сигнатуры и правил и поэтому не работают с неизвестными SQL-инъекциями. Во втором случае основным средством защиты является система разграничения доступа. Наиболее эффективными моделями разграничения доступа в настоящее время являются ролевая (Role-Based Access Control, RBAC) [Sandhu et al., 1996] и атрибутивная (Attribute-Based Access Control, ABAC) [Salehi Shahraki et al., 2020]. Однако настройка этих систем в условиях достаточно большого количества пользователей и хранимых в ЦОД таблиц данных является весьма трудоемкой задачей. Поэтому для решения проблемы выявления аномального поведения пользователей ЦОД представляется более эффективным использование моделей и методов машинного обучения.

Известно достаточно большое количество работ, в которых методы машинного обучения применяются для обнаружения SQL-инъекций, например [Joshi et al., 2014]. Эффективность этого подхода была ранее подтверждена в наших исследованиях [Саенко и др., 2022а; Саенко и др., 2022б]. Настоящая работа продолжает исследования в этом направлении. *Новизна работы* обусловлена применением нового подхода к оптимизации признакового пространства, в котором помимо известных метрик информативности признаков используется новая усредненная нормированная метрика. *Постановка задачи работы* заключается в разработке элементов методики выявления аномального поведения пользователей ЦОД, позволяющей с высокой эффективностью обнаруживать SQL-инъекции и попытки НСД к хранимым данным, используя стандартные модели машинного обучения.

1. Подход к формированию признакового пространства для машинного обучения

Формирование признакового пространства (Feature Selection) является одним из начальных этапов методов машинного обучения, в котором определяется структура наборов данных, применяемых для обучения моделей машинного обучения. В предлагаемом подходе он, в свою очередь, разделяется на два этапа: построение первоначального набора признаков; оптимизация признакового пространства.

1.1. Построение первоначального набора признаков

Для построения первоначального набора признаков следует рассмотреть структуру исходных наборов данных.

В качестве исходных наборов данных используются фрагменты регистрационного журнала системы управления базами данных (СУБД). Этот журнал состоит из отдельных записей. Каждая запись отражает факт обращения некоторого пользователя к базе данных и содержит следующие поля: дату, время, идентификатор пользователя и текст SQL-запроса, который был сформирован пользователем и выполнен со стороны СУБД. Таким образом, задача выявления аномального поведения пользователей сводится к задаче выявления аномальных SQL-запросов.

В рассматриваемом подходе первоначальный набор признаков (атрибутов набора данных) формируется из следующих категорий: ключевые слова языка SQL; сигнатуры, свойственные SQL-инъекциям; имена таблиц данных, к которым происходит обращение в SQL-запросе.

Признаки по каждой категории формируются с помощью известного метода «мешок слов» (bag-of-words) [Qader et al., 2019]. Иными словами, они определяют количество вхождений в соответствующий SQL-запрос того или иного слова или комбинации слов.

В результате признаки первой категории определяют количество вхождений того или иного ключевого слова языка SQL. Всего было отобрано 30 ключевых слов, таких как SELECT, INSERT, UPDATE, DELETE и т.д. С помощью значений этих признаков, как предполагалось, можно определить уровень сложности SQL-запроса и его тип.

Вторую категорию признаков составляют количества вхождений тех или иных сигнатур, свойственных SQL-инъекциям. Для этой цели были отобраны следующие сигнатуры, свойственные наиболее известным видам SQL-инъекций: “Execute”, “ or ”, “txtUserId”, “getRequestString”, “1=1”, “- -”, “CHAR”, “#” and “;”. Полагается, что наличие таких сигнатур в SQL-инструкциях однозначно вызвано реализацией SQL-инъекций.

Признаки третьей категории определяются количеством вхождений в SQL-запросы тех или иных имен таблиц данных. С помощью этой группы признаков, как предполагалось, можно обнаруживать аномальные SQL-запросы, в которых пользователи предпринимают попытки несанкционированного доступа.

Здесь следует отметить следующие два момента. Во-первых, кроме имен таблиц в SQL-запросах могут присутствовать имена полей (атрибутов) этих таблиц, а также значения, которые могут принимать эти поля. Естественно, учет этих элементов может повысить точность обнаружения аномальных запросов. Однако это может также привести к увеличению размерности признакового пространства и неоправданному переобучению моделей. Поэтому использование этих элементов в предлагаемом подходе отнесено нами к направлениям дальнейших исследований. Во-вторых, количество признаков в третьей категории зависит непосредственно от структуры используемой базы данных и количества содержащихся в ней таблиц данных. В нашей работе использовалась база данных, предназначенная для организации и ведения учебного процесса в высшем учебном заведении. Общее количество учитываемых в этой базе таблиц данных равнялось 141. Следовательно, общее количество признаков в первоначальном наборе составило 181: 30 признаков относятся к первой категории, 10 – ко второй категории и 141 – к третьей категории.

1.2. Оптимизация признакового пространства

Как было отмечено выше, излишне большое количество признаков может оказывать негативное влияние на точность обнаружения аномалий. Поэтому в настоящей работе решалась задача максимального сокращения первоначального набора признаков, при котором результирующая точность обнаружения аномалий не уменьшается и/или, по возможности, может даже повыситься.

Оптимизация первоначального набора признаков проводилась на основе оценки их информативности. Для этой цели использовались следующие метрики: Information Gain (Info.Gain), Information Gain Ratio (Gain Ratio), ANalysis Of VAriance (ANOVA), нормированное среднее значение этих метрик.

Метрика Info.Gain определяет «прирост информации». Она показывает уменьшение энтропии, вызванное разделением первоначального набора признаков и поиском оптимального признака, который дает наибольшее значение в соответствии со следующей формулой:

$$M_{IG}(A, a) = H(A) - H(A|a), \quad (1.1)$$

где A – признак (случайная величина), $H(A)$ – энтропия A ; $H(A|a)$ – энтропия A при заданном значении $A = a$.

Метрика Gain Ratio M_{GR} является отношением между значением метрики Info.Gain, вычисляемой согласно (1.1), и значением метрики S lit Information (Split Info), т.е. метрики разделения информации. Метрика S lit Info определяется следующим образом:

$$M_{SI}(A) = M_{SI}(A) = -\sum_{i=1}^n (p_i \cdot \log_2 p_i), \quad (1.2)$$

где A – оцениваемый признак, принимающий значения $\{a_1, a_2, \dots, a_n\}$; p_i – относительное количество раз, когда признак A принимает значение a_i . Иными словами, $p_i = N(a_i) / N$, где $N(a_i)$ – количество значений a_i признака A , N – общее количество значений признака A в выборке.

Дисперсионный анализ ANOVA представляет собой набор статистических моделей и связанных с ними процедур оценки, используемых для анализа различий между средними значениями. В своей простейшей форме ANOVA обеспечивает статистическую проверку равенства двух или более средних значений генеральной совокупности. Примеры расчет метрики информативности M_{ANOVA} на основе дисперсионного анализа можно найти в [Антипина и др., 2021].

Последняя метрика информативности $M_{\text{сред}}$ вычисляется как среднее значение первых трех нормализованных метрик: $M_{\text{сред}} = M_{IG} + M_{GR} + M_{ANOVA} / 3$.

Критерием, по которому осуществляется оставление признака в признаковом пространстве, является превышение его метрики информативности среднего значения этой метрики по всему первоначальному набору признаков. Иными словами, для признака A^* , который остается в признаковом пространстве, выполняется условие

$$M(A^*) > (M(A_1) + M(A_2) + \dots + M(A_K)) / K, \quad (1.3)$$

где $K = 181$ – общее количество признаков в первоначальном наборе.

2. Использование стандартных моделей машинного обучения

Предлагаемый подход был реализован в двух программных средах:

- на языке Python с наборами следующих библиотек: sklearn, numpy, pandas, matplotlib, Scipy, Re, PyLab, Math;
- в системе открытого доступа Orange 3.32.

Реализация на языке Python использовалась для обнаружения аномалий с использованием полного, а в системе Orange – оптимизированного набора признаков. Вычислительная среда была организована на ноутбуке Jupyter. Для создания базы данных использовалась DBMS PostgreSQL v.13.4, работающая под операционной системой Ubuntu v.13.4.

Целесообразность использования системы Orange была обусловлена более широким набором имеющихся в ней функциональных возможностей по реализации моделей и методов машинного обучения. В частности, в этой системе намного легче и нагляднее решается задача оптимизации признакового пространства. На рис. 1 приведен фрагмент результирующей таблицы, которую формирует Orange для анализа информативности признаков по выбранным метрикам Info.Gain, Gain Ratio и ANOVA. Из рисунка видно, что различные признаки имеют различную предпочтительность по включению их в итоговый набор данных относительно различных метрик информативности.

Рис. 1. Табличное представление метрик информативности признаков

Исследовались стандартные модели машинного обучения «с учителем» (supervised). Исследованию подлежали следующие наиболее популярные модели [Kotenko et al., 2018; Браницкий и др., 2019]: логистиче-

ская регрессия (LR), машина опорных векторов (SVM), дерево решений (DT), метод k -ближайших соседей (KNN), гауссов наивный Байес (GNB), многослойная нейронная сеть (MNN), случайный лес (RF).

Формирование обучающей выборки (набора данных), которая использовалась для обучения моделей машинного обучения, было выполнено исходя из фрагмента регистрационного журнала базы данных, отображающего работу пользователей с этой базой в течение 15 минут. Первоначально в этом фрагменте находилось 82192 записей. После удаления из этого набора данных дублирующих строк в нем осталось всего 1026 записей.

Затем несколько случайно выбранных записей были модифицированы таким образом, чтобы они соответствовали возможным SQL-инъекциям и попыткам несанкционированного доступа. Всего было модифицировано 50 таких записей, которые были помечены как аномальные. Для обучения использовалось 80% записей. Остальные 20% записей использовались для контрольного тестирования.

3. Экспериментальная оценка предлагаемого подхода

Сформированная описанным выше образом обучающая выборка подвергалась анализу с помощью выбранных моделей машинного обучения в двух вариантах:

- с использованием первоначального набора признаков;
- с использованием оптимизированного признакового пространства.

Полученные результаты оценки эффективности обнаружения аномалий (на основе показателя F -score [Котенко и др., 2021]) по данным контрольного тестирования для различных моделей машинного обучения представлены в табл. 1.

Таблица 1

Модель	F -score				
	Полный набор признаков	Оптимизированные наборы признаков			
		Info.Gain	Gain Ratio	ANOVA	$M_{\text{сред}}$
KNN	0,935	0,978	0,995	0,995	0,989
DT	0,935	0,935	0,935	0,935	0,935
SVM	0,974	0,984	1,000	1,000	0,995
RF	1,000	1,000	0,995	1,000	0,998
MNN	0,997	0,984	1,000	1,000	0,995
GNB	0,517	1,000	1,000	1,000	1,000
LR	0,935	0,971	0,995	0,995	0,987

Анализ полученных экспериментальных результатов позволяет сделать следующие выводы.

Во-первых, предложенный метод выявления аномального поведения пользователей ЦОД, в котором используются стандартные модели машинного обучения и обучающие наборы данных, сформированные из записей регистрационного журнала СУБД, являются результативным. Он позволяет находить аномальные SQL-запросы и, тем самым, выявлять аномальные обращения пользователей к базам данных ЦОД.

Во-вторых, выбранные для исследования модели машинного обучения показали различную эффективность по обнаружению аномалий. Так, модели SVM и GNB оказались недостаточно эффективными. Возможно, это вызвано недостаточно большим размером обучающей выборки. В свою очередь, модели LR, DT, KNN, MNN и RF показали достаточно высокую эффективность. Наибольшую эффективность продемонстрировала модель DT, которая не сделала ни одной ошибки в обнаружении аномалий.

В-третьих, оптимизация признакового пространства в целом приводит к повышению эффективности обнаружения аномалий в SQL-запросах. Практически для всех моделей машинного обучения видно повышение значения показателя F -score при использовании оптимизированных наборов признаков с использованием различных метрик информативности. При этом наибольшая эффективность обнаружения аномалий демонстрируется при использовании метрики ANOVA.

Наконец, предложенная нами метрика $M_{\text{сред}}$ занимает в общем случае промежуточное значение между ANOVA, с одной стороны, и метриками Info.Gain и Gain Ratio – с другой. Изначально ввод в рассмотрение этой метрики преследовал цель выравнивания результатов оценки информативности признаков, если для различных моделей машинного обучения наиболее предпочтительным окажется использование различных метрик информативности. Однако в случае, когда одна из рассматриваемых метрик имеет полное доминирование над остальными метриками, введение в рассмотрение усредненной метрики становится не обязательным.

Заключение

В статье приводятся результаты научного исследования, проведенного в области выявления аномального поведения пользователей ЦОД с помощью стандартных моделей машинного обучения. Предложенный метод выявления таких аномалий предполагает, что обучающие наборы данных формируются из фрагментов регистрационных журналов СУБД с помощью «мешка слов» и содержат три категории признаков, которые охватывают ключевые слова языка SQL, сигнатуры возможных SQL-инъекций и имена таблиц данных. Предложенный подход к оптимизации признаково-

го пространства основывается на использовании различных метрик информативности признаков (Info.Gain, Gain Ratio и ANOVA). Кроме того, исследованию подвергалась предложенная авторами дополнительная усредненная метрика информативности, использование которой продемонстрировало достаточно высокую эффективность обнаружения аномалий. Экспериментальная оценка предложенного метода на множестве стандартных моделей машинного обучения позволило выявить среди них наиболее предпочтительные. Дальнейшие исследования связываются с применением в рассмотренной научной области моделей машинного обучения «без учителя» (unsupervised).

Список литературы

- [Антипина и др., 2021] Антипина Н.М., Захаров В.Н., Протасов Ю.М. Однофакторный дисперсионный анализ Краскела-Уоллиса в табличном редакторе MS Excel // Инновационные образовательные технологии в современной начальной школе. – М. Изд-во "Перо", 2021.
- [Асадуллин, 2020] Асадуллин Я.Я. Управление информационной безопасностью центра обработки данных // Защита информации. Инсайд. – 2020. – № 6 (96).
- [Белянская и др., 2021] Белянская О.В., Привалов А.Н. О модели угроз информационной безопасности в центрах обработки данных // Известия Тульского государственного университета. Технические науки. – 2021. – № 9.
- [Браницкий и др., 2019] Браницкий А.А., Котенко И.В. Обнаружение сетевых атак на основе комплексирования нейронных, иммунных и нейро-нечетких классификаторов // Информационно-управляющие системы. – 2015. – № 4. – С. 69-77.
- [Воронцов и др., 2020] Воронцов Д.А., Видманов Д.В. Центры обработки данных // Colloquium-Journal. – 2020. No. 7-1 (59).
- [Ефремов, 2022] Ефремов А.Ю. Безопасная вычислительная платформа для центров обработки данных // Железные дороги мира. – 2022. – № 2.
- [Касенова, 2021] Касенова Д.А. Необходимость обеспечения информационной безопасности центра обработки данных // Modern Science. – 2021. – № 10-1.
- [Котенко и др., 2014] Котенко И.В., Саенко И.Б. Создание новых систем мониторинга и управления кибербезопасностью // Вестник Российской академии наук. – 2014. – Т. 84. № 11.
- [Котенко и др., 2021] Котенко И.В., Саенко И.Б., Браницкий А.А., Паращук И.Б., Виткова Л.А. Интеллектуальная система аналитической обработки цифрового сетевого контента для защиты от нежелательной информации // Информатика и автоматизация. – 2021. – Т. 20, № 4.
- [Маматов, 2021] Маматов Б.Т. К вопросу обеспечения безопасности центра обработки данных кредитных организаций // Global Science and Innovations: Central Asia. – 2021. – № 4 (13).
- [Мартышкин, 2022] Мартышкин А.И. Вариант реализации вычислительного кластера центра обработки данных на примере интернет-центра вуза // XXI век: итоги прошлого и проблемы настоящего плюс. – 2022. – Т. 11, № 1 (57).

- [**Мочалов и др., 2020**] Мочалов В.П., Линец Г.И., Палканов И.С. Виртуализация серверной инфраструктуры корпоративных центров обработки данных // Информационные технологии. – 2020. – Т. 18, № 3.
- [**Саенко и др., 2022а**] Саенко И.Б., Котенко И.В., Аль-Барри М.Х. Применение искусственных нейронных сетей для выявления аномального поведения пользователей центров обработки данных // Вопросы кибербезопасности. – 2022. – № 2(48).
- [**Саенко и др., 2022б**] Саенко И.Б., Аль-Барри М.Х. Обнаружение SQL-атак на центры обработки данных на основе применения бинарных классификаторов // Труды ЦНИИС. Санкт-Петербургский филиал. – 2022. – Т. 1. № 13.
- [**Чешейко, 2021**] Чешейко С.И. Особенности архитектуры центра обработки данных в медицинском учреждении // Информационные и телекоммуникационные технологии. – 2021. – № 49.
- [**Joshi et al., 2014**] Joshi A. and Geetha V. SQL Injection detection using machine learning // Proc. 2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCCCT), India, 2014.
- [**Kotenko et al., 2018**] Kotenko I., Saenko I., Branitskiy A. Framework for Mobile Internet of Things Security Monitoring based on Big Data Processing and Machine Learning // IEEE Access. – 2018. – Vol. 6.
- [**Marashdeh et al., 2021**] Marashdeh Z., Suwais K. and Alia M. A Survey on SQL Injection Attack: Detection and Challenges // Proc. 2021 International Conference on Information Technology (ICIT), Jordan, 2021.
- [**Qader et al., 2019**] Qader W.A., Ameen M.M. and Ahmed B.I. An Overview of Bag of Words; Importance, Implementation, Applications, and Challenges // Proc. 2019 International Engineering Conference (IEC), Iraq, 2019.
- [**Salehi Shahraki et al., 2020**] Salehi Shahraki A., Rudolph C. and Grobler M. Attribute-Based Data Access Control for Multi-authority System // Proc. 2020 IEEE 19th International Conference on Trust, Security and Privacy in Computing and Communications (TrustCom), China, 2020.
- [**Sandhu et al., 1996**] Sandhu R.S., Coyne E.J., Feinstein H.L. and Youman C.E. Role-based access control models // Computer. – 1996. – Vol. 29, No. 2.

НЕЙРОСЕТЕВОЙ ПОДХОД К СТРУКТУРНО-СЕМАНТИЧЕСКОМУ АНАЛИЗУ ОЦИФРОВАННЫХ ДОКУМЕНТОВ

Н.С. Скрынников (*skrynnikovns@mpei.ru*)

О.Л. Моросин (*morosinol@mpei.ru*)

НИУ «МЭИ», Москва

В работе описывается способ применения нейросетевого подхода к задаче структурно-семантического анализа документов. Отличительной особенностью разработанного алгоритма является совместное использование как текстовых, так и графических элементов документа, что повышает качество распознавания даже в условиях зашумленных входных данных.

Ключевые слова: нейронные сети, распознавание документов, компьютерное зрение.

Введение

Цифровые копии документов часто используются в различных организациях. Существуют алгоритмы для преобразования фотографии документа в текст, но для полной автоматизации процесса обработки недостаточно обладать только текстовой информацией. Необходимо учитывать взаимное расположение слов на документе, расстояние до не-текстовых элементов, характер написания текста и другие параметры.

В последнее десятилетие, при решении задач искусственного интеллекта широкое распространение получили нейросетевые алгоритмы. Широкое применение получила система распознавания текста Tesseract, которая используется для поиска текстовых элементов на изображении. Она использует простые эвристические алгоритмы для локализации текстовых строк, и нейронную сеть типа LSTM для преобразования изображений строк в текст. Также существуют алгоритмы для анализа структуры документа: в [Gruning, 2018] предлагается использовать Unet-подобную архитектуру с последующей кластеризацией для выделения текстовых линий, но предложенный подход работает только с документами определенной структуры (в частности, статьи в научных журналах).

В данной работе предлагается метод детекции пар «ключ-значение», которые присутствуют на документах различных видов, и их внешний вид практически не зависит от языка и структуры документа. Пример этого структурного элемента показан на рис. 1.




Рис. 1. Пример структурных пар «ключ-значение». Светло-серым цветом выделен «ключ» элемента, темно-серым – соответствующее этому ключу «значение»

1. Связанные работы

При решении задачи поиска структурных элементов на изображении документа могут применяться следующие подходы:

1. Документ рассматривается как совокупность графических объектов, без учета смысла слов
2. Документ рассматривается как линейная последовательность слов, без учета не-текстовых элементов
3. Комбинированные архитектуры

В архитектурах, основанных на графических признаках, документ рассматривается как изображение и совокупность охватывающих прямоугольников слов [Subramani, 2020]. В таком случае, задача машинного обучения может ставиться как:

- задача классификации – необходимо отнести каждый охватывающий прямоугольник к одному из заранее определенных классов.
- задача регрессии – в таком случае, необходимо описать охватывающий прямоугольник вокруг каждой отдельной структуры.
- задача семантической сегментации – необходимо отнести каждый пиксель изображения к одному из классов.

В [Katti, 2018] для извлечения структурной информации из документа используется нейронная сеть архитектуры FCN. Для постобработки результата применялись методы нелинейной оптимизации. В исходном датасете ключи и значения элементов были написаны различным почерком (ключи – печатным текстом, значения – от руки), авторы отмечают, что этот метод не является универсальным. В [Rasmus 2017] для извлечения про-

странственной информации из документа применялось посимвольное кодирование. Каждому печатному символу на документе был присвоен определенный цвет, после чего с помощью сверточной нейронной сети определялись координаты охватывающих прямоугольников слов и их классы.

При использовании языковых моделей задача распознавания документа сводится к задаче поиска именованных сущностей. Каждому слову в последовательности ставится в соответствие метка согласно BIO-разметке, после чего производится классификация последовательности слов. В [Rasmus 2017] для решения задачи классификации используется архитектура LSTM. Для каждого слова вычисляются три группы признаков: числовые, текстовые, булевы.

В [Majumder 2020] для решения похожей задачи также используется BERT-подобная архитектура сети, но относительные координаты вычисляются иначе. Координаты нормируются по высоте и ширине листа, после чего для каждого блока текста определяется множество его соседей (здесь соседями считаются те слова, которые находятся на расстоянии от целевого слова, которое не превышает пороговое). После этого, векторные представления целевого слова и всех его соседей отправляются на вход нейронной сети, которая предсказывает, какой из соседей является ключом.

В [Xu 2020a] представлена архитектура сети LayoutLM. Она построена на основе архитектуры Transfor er, и используется для классификации последовательности слов. При обучении модели используется как позиционная и семантическая информация, так и данные о местоположении слов на картинке.

Описанные методы объединяют следующие черты:

- Качество работы методов, использующие как структурные признаки, так и семантические, превосходит те, что используют только один вид информации;
- Используются только текстовые элементы, при этом горизонтальные линии, печати, подписи и другие графические объекты на изображении остаются незадействованными.

2. Описание метода

Для определения того, чем является то или иное слово на документе, используется нейронная сеть. На вход нейронной сети подается изображение документа, массив координат слов и горизонтальных линий, и текст слов. Входные данные проходят через этап векторизации, после чего полученные эмбединги конкатенируются и отправляются в нейронную сеть типа Transfor er. Преобразованные вектора далее отправляются в полносвязный слой сети, на котором проходит классификация на 5 классов: Ключ, Значение, Заголовок, Строка текста, Линия.

Для каждого из 4 текстовых классов (ключ, значение, заголовок, строка текста) предусматривается три тега согласно ВЮ-разметке, для линий – одиночная метка класса, так как линия является одним токеном.

2.1. Предобработка и векторизация

Текстовые признаки. Входная последовательность слов токенизируется с помощью алгоритма WordPiece [Wu 2016]. Финальное векторное представление последовательности является конкатенацией трех векторных представлений: векторного представления токена, суммы векторных представлений отдельных сегментов токена и векторного представления позиции токена в плоском тексте документа.

Визуальные признаки. Для извлечения визуальных признаков используется нейронная сеть ResNeXt-FPN с размером входного слоя 224x224. После преобразования, результат линейруется.

Пространственные признаки. Все координаты нормализуются и отображаются на шкалу от 0 до 1000, после чего каждая из координат преобразуется в векторное представление согласно алгоритму [Xu 2020b].

Полученные векторные представления объединяются в вектор длины 512, который затем отправляется на вход нейронной сети типа Transformer.

2.2. Архитектура нейронной сети

В качестве нейронной сети для получения эмбеддингов для классификации предлагается использовать архитектуру LayoutLM2 [Xu 2020b]. Её схема представлена на рис. 2.

Архитектура сети состоит из следующих блоков:

1. Вход сети – окно длины 512
2. Блок векторизации – объединяет в себе 4 вида векторных представлений:
 - Текстовые (векторное представление слова через BERT)
 - 2D-позиционные (положение слова на документе)
 - 1D-позиционные (позиция слова в плоском тексте)
 - Сегментные (векторные представления сегментов слова)
3. Блок Transformer – 24 слоя, архитектура схожая с BERT, 200 млн. параметров.

Так как задача рассматривается как задача классификации последовательности, модель будет классифицировать слова согласно ВЮ-разметке. Обучение для конкретной задачи является достаточно трудоемким, поэтому веса будут инициализированы из претренированной модели.

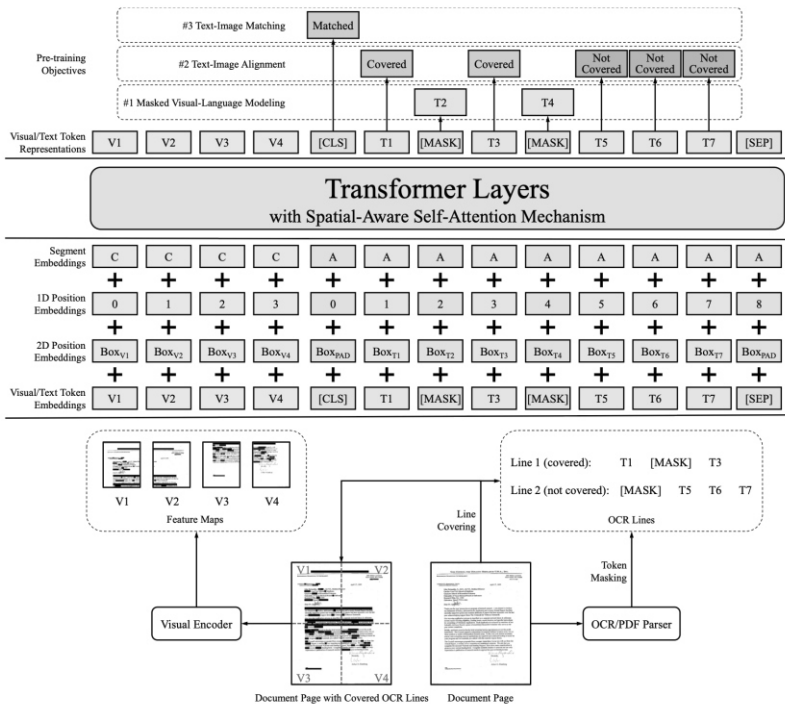


Рис. 2. Иллюстрация архитектуры и процесса обучения LayoutLM2

Также в исходном наборе данных не используются горизонтальные линии: в ней представлены только слова. Для того, чтобы модель могла переиспользовать признаки, полученные при анализе слов, процесс предобработки данных будет организован следующим образом:

1. Поиск линий осуществляется с помощью алгоритма LSD [Gioi 2012]. Результатом его работы будет список кортежей вида (x_0, y_0, x_1, y_1) – это охватывающие прямоугольники линий.
2. Все линии считаются словами с текстом `<LINE>` (этот токен уникальный и более нигде в тексте не встречается).

3. Описание набора данных

Для проведения экспериментов был выбран набор тестовых данных FUNSD [Vu, 2020]. Он состоит из 199 размеченных черно-белых изображений отсканированных документов.

Изображения разбиты на тренировочную и тестовую выборку: 149 документов в тренировочной и 50 в тестовой. Все документы на картинке одностраничные (т.е., нет документов с переносом элементов с одной страницы на другую).

Каждому изображению документа ставится в соответствии файл в формате json. В этом файле описаны структурные элементы, которые содержатся на изображении:

1. На элементе могут присутствовать так называемые “сущности”, каждая из которых представляет собой набор слов. Каждая семантическая сущность имеет уникальный идентификатор, метку класса и список слов, принадлежащих данной сущности. Метки класса следующие:

- QUESTION – обозначает “ключ” k-v структурыж
- ANSWER – обозначает “значение” k-v структурыж
- TITLE – обозначает заголовокж
- OTHER – обозначает строку текста, которая не относится к предыдущим 3 классам.

2. Список слов представляет собой кортежи, состоящие из:

- Списка координат слова (x0, y0, x1, y1).
- Текста слова.

Так как в исходном наборе данных отсутствовала информация о текстовых линиях, была выполнена их доразметка. Каждая линия представляет собой отдельное «слово» с текстом “<LINE>” и координатами левого верхнего и правого нижнего конца охватывающего прямоугольника. В разметке линиям соответствовал токен LINE.

4. План экспериментов и результаты

4.1. План экспериментов

На вход сети подается последовательность токенов, совместно с их метками классов. Качество работы модели оценивается с помощью метрики F1, отдельно по каждому классу.

Важной особенностью является то, как сортируются токены текста при подаче на вход модели. В оригинальной работе токены не сортировались, слова были расположены в порядке их следования в сущности. Если на странице было несколько элементов вида “ключ-значение”, то текст слов, из которых они были образованы, подавался в модель последовательно - сначала первый элемент, затем второй. Таким образом, на вход модели всегда поступал сначала ключ, а потом значение. Чтобы исключить предвзятость, использовались различные сортировки:

Применяемая сортировка могла повлиять на репрезентативность результатов. В реальной жизни мы не имеем априорной информации о том, в каком порядке необходимо читать текст – эту информацию человек получает, изучая смысл текста. Для того, чтобы исключить такого рода предвзятость, дополнительно использовались следующие сортировки:

1. Лексикографическая сортировка: слова сортируются по X-координате, если по высоте они друг от друга не дальше, чем медианная высота слова. В противном случае они сортируются по Y-координате. Такой способ сортировки позволяет исключить априорную информацию о сущностях из рассмотрения.

2. Случайная сортировка – все слова перемешиваются случайным образом. Этот способ позволяет оценить, насколько на точность классификации влияет наличие линий в отрыве от семантических признаков.

4.2. Результаты

Первым был поставлен эксперимент по воспроизведению результатов работы модели LayoutLM2 из [Xu 2020b]. При обучении модели использовалась оригинальная сортировка слов (в порядке следования сущностей), но тестирование выполнялось на тексте, отсортированном в лексикографическом порядке (так как при использовании системы на неразмеченных документах мы не будем обладать априорной информации о том, как слова объединены в сущности).

Результаты тестирования приведены в табл. 1. Также в таблицу добавлены результаты работы модели RoBERTa base (без графических признаков). Колонка “всего” показывает точность классификации по всем элементам.

Таблица 1

	Ключ	Значение	Заголовок	Всего
RoBERTa base	-	-	-	0.603
LayoutLM2 сортировка сущностей	-	-	-	0.8276
LayoutLM2 лексикографическая сортировка	0.7758	0.6663	0.4976	0.7096

Результаты эксперимента показывают, что добавление пространственных признаков в модель повышает качество классификации. Видно, что порядок сортировки токенов оказывается важен - если сортировка токенов при обучении и тестировании была разной, качество работы сильно снизится.

Вторым был поставлен эксперимент по обучению модели на основе лексикографической сортировки токенов. Из табл. 2 видно, что наличие линий повышает точность классификации. Метрика F1 для класса “Линия” равна 1, это связано с тем, что для линий используются специальные токены, модель легко обучается их классифицировать.

Таблица 2

	Ключ	Значение	Заголовок	Всего
Без линий	0.8101	0.7896	0.543	0.7861
С линиями	0.8119	0.7963	0.5668	0.836

Последним был поставлен эксперимент по обучению модели со случайным порядком следования токенов. Результаты эксперимента представлены в табл. 3. Из результатов видно, что добавление линий повышает качество распознавания даже в том случае, если ключи и значения не упорядочены.

Таблица 3

	Ключ	Значение	Заголовок	Всего
Без линий	0.6893	0.5909	0.4914	0.6198
С линиями	0.6995	0.6111	0.4921	0.6782

График изменения функции потерь для модели с наилучшим показателем F1-меры (эксперимент 2, “модель с линиями”) приведен на рис. 3. Обучение производилось на протяжении 5 эпох (всего было проведено 1000 итераций). Темп обучения постепенно снижался: начиная с $2 \cdot 10^{-5}$, линейно уменьшался до 0 до 1000-й эпохи. Наилучший результат был достигнут на 1000-й эпохе, значение функции потерь составило 0.0284.




Рис. 3. График изменения функции потерь на тренировочной выборке

Заключение

В данной работе представлена нейросетевая архитектура для обработки структурно-семантической информации оцифрованного документа. Произведена разметка набора эталонных данных, на основании которых будет производиться оценка качества работы системы. Для проведения сравнительного анализа, выполнены вычислительные эксперименты, в результате которых удалось определить наилучший способ преобразования входных данных при обучении. Также было показано, что гипотеза о важности не-текстовых элементов страницы для анализа подтверждается: добавление объектов линий в обучающую выборку действительно позволяет повысить точность распознавания структурных элементов.

Список литературы

- [Gioi 2012] R.G. von Gioi, J. Jakubowicz, J.-M. Morel, and G. Randall. LSD: a line segment detector // *Image Processing on Line*. – 2012. – Vol. 2. – P. 35-55.
- [Gruning 2018] Tobias Gruning, Gundra Leifert, Tobias Strauß, and Roger Labahn. 2018. A two-stage method for text line detection in historical documents // *arXiv preprint arXiv:1802.03345*. – 2018.
- [Katti 2018] Katti A.R., Reisswig C., Guder C., Brarda S., Bikel S., Höhne J., & Faddoul J.B. Chargrid: Towards Understanding 2D Documents. EMNLP. 2018.
- [Majumder 2020] Majumder B.P., Potti N., Tata S., Wendt J.B., Zhao Q., and Najork M. Representation Learning for Information Extraction from Form-like Documents // presented at the Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. – 2020. – Doi: 10.18653/v1/2020.acl-main.580.
- [Rasmus 2017] Rasmus Berg Palm, Ole Winther, and Florian Laws. Cloudscan-a configuration-free invoice analysis system using recurrent neural networks // In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR). – IEEE, 2017. – Vol. 1. – P. 406-413.
- [Subramani 2020] Subramani, Nishant, et al. A Survey of Deep Learning Approaches for OCR and Document Understanding // *arXiv preprint arXiv:2011.13534*. – 2020.
- [Vu 2020] Vu, Hieu M., and Diep Thi-Ngoc Nguyen. Revising FUNSD dataset for key-value detection in document images // *arXiv preprint arXiv:2010.05322* – 2020.
- [Wu 2016] Wu, Yonghui, et al. Google's neural machine translation system: Bridging the gap between human and machine translation // *arXiv preprint arXiv:1609.08144*. – 2016.
- [Xu 2020a] Xu, Yiheng, et al. Layoutlm: Pre-training of text and layout for document image understanding // *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. – 2020.
- [Xu 2020b] Xu, Yang, et al. LayoutLMv2: Multi-modal Pre-training for Visually-Rich Document Understanding // *arXiv preprint arXiv:2012.14740*. – 2020.

СЕКЦИЯ 5

**ИНТЕЛЛЕКТУАЛЬНЫЕ
СИСТЕМЫ ПОДДЕРЖКИ
ПРИНЯТИЯ РЕШЕНИЙ
И УПРАВЛЕНИЯ**

УДК 004.82

**СОЗДАНИЕ ЦИФРОВЫХ ПАЦИЕНТ-
ОРИЕНТИРОВАННЫХ РЕКОМЕНДАЦИЙ НА ОСНОВЕ
МНОГОУРОВНЕВОЙ ГРАНУЛЯЦИИ***

Т.В. Афанасьева (*afanaseva.tv@rea.ru*)
Российский экономический университет
имени Г.В. Плеханова, Москва

П.В. Платов (*chipa.platov@gmail.com*)
Ульяновский государственный технический университет,
Ульяновск

Развитие цифровых технологий в области здравоохранения, профилактики заболеваний и информированности пациентов с имеющимися заболеваниями привело к возникновению новых систем поддержки пациентов, получивших название системы рекомендации по управлению здоровьем. В статье на основе анализа таких систем вводится определение пациент-ориентированных систем, предлагаются модели здоровья пациента и цифровых пациент-

* Работа выполнена при финансовой поддержке РФ (проект № 20-07-00672).

ориентированных рекомендаций, а также сценарий их создания с использованием многоуровневой информационной грануляции в пространственно-темпоральном аспекте.

Ключевые слова: рекомендательные системы, многоуровневая грануляция данных, цифровые пациент-ориентированные рекомендации, пациент-ориентированные системы.

Введение

Развитие информатизации в лечебно-профилактических учреждениях следует тенденциям развития корпоративных информационных систем общего назначения. После автоматизации административных, экономических и операционных процессов современными целями информатизации выступают автоматизация лечебно-диагностического процесса, разработка систем поддержки принятия врачебных решений и систем вовлечения граждан в заботу о своем здоровье [Sutton et al. 2020]. Системы поддержки принятия решений в области здравоохранения появились как инструменты, помогающие медицинским работникам и пациентам принимать более обоснованные решения, связанные с управлением риском развития заболеваний, улучшением качества жизни и сохранением здоровья. В настоящее время не существует одного определения термина система поддержки принятия врачебных решений, в этой статье мы придерживаемся определения, приведенного в работе [Гусев и др. 2017]: «Система поддержки принятия врачебных решений (СППВР) – это программное обеспечение, позволяющее путем сбора и анализа информации влиять на принятие врачом решения при обследовании пациента, диагностики, назначении лечения с целью снижения ошибок и повышения качества оказываемой медицинской помощи».

В рамках лечебно-диагностического процесса согласно содержанию и структуре клинических рекомендаций врач должен руководствоваться моделью пациента, которую он строит путем выдвижения и проверки диагностических гипотез на основе своего опыта, анамнеза, совокупности клинических, лабораторных и инструментальных диагностических признаков пациента [Авдеев, 2019]. Одним из направлений в области автоматизации лечебно-диагностического процесса следует отнести СППВР для первичного звена, так как в этот класс систем входит решение большого количества задач, основанных на анализе и обобщении первичных данных о пациенте, их обработке для создания модели пациента и пациент-ориентированных рекомендаций. Так, сервис из класса СППВР для врачей первичного звена «Гиппократ» создан, чтобы помочь врачу не упустить ранний дебют заболеваний, определить диагностические дейст-

вия, выполнить интерпретацию анализов на основе национальных клинических протоколов и рекомендаций [Верткин, 2021]. В состав исходных данных СППВР «Гиппократ» включены клинические опросники для пациентов по сбору анамнестических данных, на основе которых система генерирует последовательность действий врача и перечень лабораторных и инструментальных тестов для подтверждения диагноза по МКБ-10, а также связанные с ним необходимые методические материалы.

В результате лечебно-диагностического процесса врач создает цифровой документ медицинского заключения с медицинскими назначениями и рекомендациями пациенту, включающие разные аспекты по управлению здоровьем и улучшению качества жизни. К ним можно отнести коды заболеваний, общие рекомендации по здоровому образу жизни и питания, варианты лечения, тактику мониторинга ряда показателей и консультации у профильных врачей. Получение такой новой информации в краткой форме медицинского заключения может вызвать у пациента когнитивный диссонанс, состояние дискомфорта, так как он может не сразу принять и понять, потому что эта информация расходится с его восприятием себя, требует изменения поведения, временных и финансовых затрат, которые он не в состоянии сразу оценить и сопоставить с положительными и отрицательными эффектами. Неопределенность, возникающая в следствие этого, часто приводит к недостаточной приверженности пациента к следованию врачебным рекомендациям, назначениями и лечению. Причинами низкой приверженности могут быть нежелание изменять образа жизни и поведения, отсутствие беспокоящих симптомов, нехватка времени, сомнение в необходимости выполнять рекомендации врача, отсутствие положительной обратной связи, нежелание считать себя имеющим заболевания, недостаточная информация о том, как с минимальными затратами следовать рекомендациям, забывчивость, недостаточная медицинская грамотность и информированность, а также психологические установки и убеждения [Мачильская, 2016].

Так, в статье [Kleinsinger, 2018] показано, что несоблюдение тактики лечения у пациентов с хроническими заболеваниями чрезвычайно распространено и составляет от 40% до 50% пациентов, которым назначают лекарства для лечения хронических состояний. Считается, что это несоблюдение назначенного лечения является причиной как минимум 100 000 предотвратимых смертей.

По данным исследования ЭССЕ-РФ (Эпидемиология сердечно-сосудистых заболеваний в различных регионах Российской Федерации) за 2012-2013 гг., включавшем лиц в возрасте 25-64 лет из 13 регионов России, распространенность артериальной гипертензии в популяции составила 43% (47,3% среди мужчин и 39,6% среди женщин). Обращает внима-

ние, что только 17,6% из лиц с артериальной гипертензией принимали препараты, из них эффективно лечились только 10% больных, а 15,5% – лечились не эффективно. Причем, среди тех, кто не следовал рекомендациям врача, преобладали мужчины (24% vs 13%) [Шальнова и др. 2018].

Вовлечение пациентов в процесс управления своим здоровьем является новым направлением развития информационных технологий, ориентированных на повышение приверженности пациента, так как именно пациент в первую очередь принимает решение в каком объеме выполнять назначения и рекомендации медицинского заключения. В исследовании [Вяткина, 2019] рассматриваются вопросы о влиянии медицинской грамотности на эффективность лечебно-диагностического процесса. В этой работе показано, что недостаток информации, переоценка пациентом собственных знаний, игнорирование врачебных назначений и рекомендаций, самолечение, опора на ненадежные источники информации могут оказать существенное негативное влияние на его здоровье.

Для решения проблемы недостаточной приверженности, низкой медицинской грамотности и для обеспечения вовлеченности пациентов в управление своим здоровьем разрабатываются информационные системы, получившие название рекомендательные системы по здоровью (Health Recommendation Systems (HRS)). Общая цель HRS - расширить возможности людей по мониторингу и улучшению своего здоровья с помощью персонализированных рекомендаций на основе технологий. В работе [Ricci et al., 2011] рекомендательные системы определяются как «программные инструменты и методы, предлагающие информационные элементы, которые могут быть полезны пользователю». Чтобы выбрать такие информационные элементы из большого объема хранимой информации и упорядочить их по степени полезности, используются оценки информационных элементов и активность пользователя в сети. Концептуальная идея рекомендательных систем по здоровью заключается в извлечении знаний о предпочтениях пациентов и предоставлении подходящих информационных элементов (рекомендаций).

В систематическом обзоре [De Stoon et al., 2021] отмечается, что получаемые рекомендации в HRS можно классифицировать по четырем основаниям: образ жизни, питание, общая информация о здравоохранении и конкретные состояния здоровья (заболевания). Резюмируя, можно заключить, что в противоположность СППВР рекомендательные системы по здоровью сфокусированы на поддержку пациентов по следованию принципам здорового образа жизни и сбалансированного питания, повышению медицинской грамотности и имеют неоспоримую ценность для профилактики заболеваний и повышению приверженности пациентов. Однако, сценарии создания рекомендаций в HRS ориентируются на использование

оценок пользователей или сходство рекомендательных пунктов, и не учитывают показатели здоровья и профессиональные медицинские знания. Чтобы устранить этот пробел, целью данной статьи является разработать структуру цифровых пациент-ориентированных рекомендаций и сценарий их создания, которые учитывают показатели здоровья пациента и профессиональные медицинские знания.

Чтобы обеспечить согласованность используемых подходов и объяснимость результатов, предлагаемый сценарий создания цифровых пациент-ориентированных рекомендаций будет приведен в рамках теории информационной грануляции [Zadeh, 1997], [Pedrycz, 2018], [Афанасьева и др., 2016]. Теория грануляции и гранулярных вычислений применяются с двумя основными взаимодополняющими целями, как указано в [Yao, 2005]. Одна цель — моделировать рациональное структурированное мышление путем абстрагирования и концептуализации, а другая цель — прикладная, она определяет систематический способ анализировать, понимать, представлять, и решать реальные проблемы на различных уровнях детализации, так, как это делает человек. Использование гранулярности в представлении знаний для создания цифровых пациент-ориентированных рекомендаций обусловлено (1) нечеткостью и неполнотой информации, получаемой от пациента, (2) разными подходами к агрегированию данных, в том числе на основе интервалов значений (3) требованием лингвистической формы представления результатов.

1. Обзор подходов к созданию цифровых рекомендаций

Сценарии создания рекомендаций, используемые в рекомендательных системах, в том числе по здоровью, обычно делят на три основных класса:

- (1) коллаборативная (совместная) фильтрация,
- (2) Контентная фильтрация
- (3) Фильтрация на основе знаний

В статье [Tran et al., 2021] приводится обзор рекомендательных, которые различаются по сценариям и темам рекомендаций. Рассматриваются рекомендации по здоровому питанию, рекомендации по лекарствам, прогноз состояния здоровья, рекомендации по физической активности и приводятся сценарии создания рекомендаций, такие как: коллаборативная фильтрация, контекстная фильтрация, а также сценарии, основанные на знаниях, в том числе получаемые методами машинного обучения (классификации, кластеризации, дереве решений).

Большинство алгоритмов коллаборативной (совместной) фильтрации начинают с поиска набора похожих пользователей, чьи выбранные и оцененные пункты перекрываются с оцененными вами пунктами. В результате ваши рекомендации содержат пункты этих похожих пользователей,

исключая пункты, которые вы уже выбрали и оценили. Основной сценарий совместной фильтрации базируется на гипотезе: «Если пациенты имеют схожие заболевания или состояния здоровья, то они будут иметь аналогичные методы лечения, медицинские услуги и рекомендации по образу жизни». К недостаткам такого сценария следует отнести обобщенный характер рекомендаций, необходимость наличия репрезентативных данных о множестве пациентов и недостаточная релевантность рекомендаций для конкретного пациента в связи с индивидуальными особенностями и предпочтениями.

Рекомендации, создаваемые на основе контента основаны на поиске похожих пунктов, а не похожих пользователей. Этот подход предлагает медицинские услуги, которые соответствуют состоянию здоровья/ситуации болезни пациента и аналогичны тем, которые были назначены ему/ей в прошлом. Применительно к пациентам ограничение сценариев создания рекомендаций на основе контента заключается в избыточности, неактуальности и неточности рекомендаций, необходимости иметь репрезентативную базу рекомендаций. Часто такие сценарии применимы к поиску текстовых медицинских информационных источников или фрагментов из электронных медицинских карт [Jannach et al., 2011].

Нерешенная проблема доступности качественных данных по множеству пациентов привела к развитию систем создания рекомендаций, использующих знания, такие системы получили название системы рекомендаций, основанные на знаниях. В отличие от рекомендательных систем, которые создают рекомендации по сходным рекомендуемым пунктам или похожим пациентам, рекомендательные системы, основанные на знаниях, могут создавать рекомендации, учитывающие особенности, ограничения, состояния здоровья и предпочтения конкретного пациента. Применение правил логических выводов, методов машинного обучения, математических моделей и явных знаний – ключевая особенность рекомендательных сценариев, основанных на знаниях [Bouhissi et al., 2019]. Сценарий создания рекомендаций, основанных на знаниях, опирается на экспертные знания, на знания, извлекаемых из официальных медицинских руководств и на знания о состоянии здоровья пациента [Kobriskii et al., 2019], [Gil et al., 2019]. Ограничениями рекомендательных систем, основанных на знаниях, согласно современной публикации являются неполнота медицинских знаний, отсутствие возможности мониторинга и анализа тенденций изменения состояния здоровья пациента, отсутствие формальных описаний используемых моделей рекомендаций [Liu et al., 2021].

Таким образом, можно сделать следующие выводы. Направление рекомендательных систем по управлению здоровьем находится на этапе становления и активно развивается, в котором уделяется большое внима-

ние медицинской грамотности, активности и вовлеченности пациентов [Bader et al., 2022], [Ambika et al., 2015]. Наиболее релевантными и полезными следует считать рекомендательные системы, основанные на знаниях в рамках принципов доказательной медицины.

Рекомендательные системы по управлению здоровьем, основанные на знаниях в рамках принципов доказательной медицины, будем называть *пациент-ориентированными рекомендательными системами* (ПАРС), если они:

а. предназначены для использования пациентами и пользователями, не имеющими заболевания, в целях мониторинга показателей здоровья, профилактики и раннего обнаружения заболеваний,

б. генерируют *базовые рекомендации* на основе цифровой модели показателей здоровья пользователя и знаний доказательной медицины, представленных в руководствах и методических материалах министерства здравоохранения или профессиональных медицинских сообществ и применяемые в клинической практике. Базовые рекомендации не включают рекомендации по медикаментозному вмешательству или постановку диагноза заболевания.

с. имеют возможность расширения функций для корректировки и уточнения базовых рекомендаций лечащим врачом и обмена данными с электронными медицинскими картами и гаджетами, обеспечивающими сбор показателей здоровья.

Так как базовые рекомендации создаются пациент-ориентированными рекомендательными системами на основе цифровых технологий обезличенного хранения, обработки и коммуникаций, то такие рекомендации будем называть *цифровыми пациент-ориентированными рекомендациями*.

Анализ ранее выполненных исследований в области рекомендательных систем по здоровью показал, что вопросам генерации, представления и моделирования цифровых пациент-ориентированных рекомендаций не уделено достаточного внимания.

2. Сценарий генерации цифровых пациент-ориентированных рекомендаций

Наш подход к созданию цифровых пациент-ориентированных рекомендаций опирается на теорию грануляции, поскольку понятие грануляции возникло как естественная потребность в обобщенном представлении информации, ориентированном на человека, для поддержки процессов понимания данных и преобразования информации в семантически значимые сущности.

Представим цифровую модель показателей здоровья пациента, используемую в ПАРС, в виде совокупности значений

$$X = \{x_{jt}, x_{jt} \subseteq \mathbb{R}, j = 1, 2, \dots, mk; t = 1, \dots, tk, \forall t x_{jt} \in [\min_{x_j}, \max_{x_j}]\},$$

наблюдаемых на временном интервале $T=[1, tk]$ в пространстве показателей

$$M = \{m_j, j = 1, 2, \dots, mk\},$$

Под цифровой пациент-ориентированной рекомендацией будем понимать текст, структура которого приближена к структуре медицинского заключения [Клинические рекомендации, 2020] в части рекомендаций по мониторингу показателей здоровья, целей и плана достижения целей без рекомендаций по лечению.

В целом, структуру цифровых пациент-ориентированных рекомендаций можно охарактеризовать вопросно-ответной моделью вида ЧПК (Что рекомендуется сделать, Почему это рекомендуется сделать, Как эффективнее выполнить рекомендации).

Тогда цифровые пациент-ориентированные рекомендации определим в виде нижеприведенной модели:

$$R = \{EsG, Es, Plan\}.$$

Компонента *EsG* отвечает на вопрос «Что рекомендуется сделать?» и содержит информацию о степени срочности и типе медицинской помощи, о целевых значениях и тенденциях по каждому показателю здоровья, требующему коррекции.

Объяснительная компонента *Es* содержит ответ на вопрос «Почему это рекомендуется?», она включает дескриптивные оценки *Des* и предиктивные оценки *Pred*, полученные по множеству показателей здоровья, имеющих отклонения.

Индивидуальный план эффективных действий *Plan* отвечает на вопрос «Как эффективнее выполнить рекомендации?» и ориентирован на достижение целей, определенных в компоненте *EsG*. Он может включать рекомендации по образу жизни, по оптимизации и коррекции питания, по релевантным физическим нагрузкам, график проведения мониторинговых и скрининговых исследований, консультаций медицинских специалистов, в том числе срочных. Очевидно, что для создания пациент-ориентированных рекомендаций указанной структуры необходимы знания *Z*, полученные из источников доказательной медицины и используемые в практике медицинских исследований.

Используя введенные обозначения, сформулируем постановку задачи генерации цифровых пациент-ориентированных рекомендаций: имея цифровую модель показателей здоровья пациента *X* по показателям *M* и модель медицинских знаний *Z* требуется получить цифровые пациент-ориентированные рекомендации *R*, т.е. построить отображение

$$X \times M \times Z \rightarrow R.$$

В настоящей статье задача генерации цифровых пациент-ориентированных рекомендаций будет решаться на основе теории информационной грануляции (ИГ), учитывая, что назначение ИГ - представлять знания, извлеченные из данных, согласованные с экспертными знаниями [Pedrycz, 2018], на различных уровнях абстракции с использованием лингвистических терминов и обобщенных ограничений для них [Zadeh, 2006].

Для решения этой проблемы предлагаются модели здоровья пациента, представленные на четырех уровнях грануляции. Для представления ИГ в тексте рекомендаций будем использовать их лингвистическую форму в виде пропозиций (предложений-утверждений), формальную основу которых образуют протоформы [Zadeh, 2002].

На первом уровне грануляции используется концепция нечетких множеств как обобщенных ограничений на X для определения информационных гранул состояния каждого показателя здоровья, включенных в цифровую модель пациента. Для создания таких гранул используется множество медицинских знаний $Z1 \subset Z$ в виде «референсных интервалов» каждого показателя модели X .

В результате создаются информационные гранулы состояния, оценивающие проблемы в здоровье пациента в лингвистических терминах, как степени отклонения значений каждого показателя от «референсных интервалов», определяемых медицинскими руководствами. Примером лингвистических терминов, именующих информационные гранулы состояния, может служить упорядоченное терм-множество $Sy = \{\text{«очень низкий»}, \text{«низкий»}, \text{«пониженный»}, \text{«в пределах нормы»}, \text{«повышенный»}, \text{«высокий»}, \text{«очень высокий»}\}$, общее для лингвистических переменных числовых показателей здоровья. Тогда методом грануляции первого уровня будет фаззификация значений с последующей дефаззификацией и определением элемента множества Sy с максимальной степенью принадлежности. Это позволяет перейти от цифровой модели показателей здоровья к гранулярной дескриптивной модели показателей

$$Y = \{y_{jt}, j = 1, 2, \dots, mk, t = 1, \dots, tk\}$$

определенной на множестве показателей M , лингвистические значения которых $y_{jt} \in Sy$ обозначают наименование информационной гранулы первого уровня, характеризующие степень отклонений значений x_{jt} показателей m_j от границ «референсных интервалов». Тогда протоформа $P1: m_j \text{ is } y_{jt}$ представляет информационную гранулу первого уровня, которая выражается пропозицией «показатель m_j является y_{jt} в момент времени t ».

На втором уровне грануляции обрабатываются информационные гранулы первого уровня. Так как на множестве элементов Sy существует бинарное отношение частичного порядка со свойствами рефлексивности, транзитивности и антисимметричности, то по содержанию это отношение, может фиксировать тип изменения между двумя информационными гранулами первого уровня одного показателя в разные моменты времени. Для обозначения информационных гранул, представляющих тенденции изменения отдельного показателя здоровья на интервале наблюдения $T=[1,tk]$, целесообразно использовать терм-множество $Sb=\{\text{«значительное падение»}, \text{«падение»}, \text{«стабильность»}, \text{«рост»}, \text{«значительный рост»}\}$, элементы которого могут быть получены на основе свойства частичного порядка с использованием системы логических правил. Тогда гранулярная предиктивная модель показателей здоровья пациента второго уровня может быть представлена в виде множества тенденций, упорядоченных по номерам исследуемых показателей

$$B = \{b_{jt}, j = 1, 2, \dots, mk, t = tk\},$$

где $b_j \in Sb$ представляет наименование информационной гранулы тенденции показателя. Тогда протоформа $P21: \text{for } tk \ m_j \text{ is } b_j$ определяет информационную гранулу второго уровня, которая может быть выражена пропозицией «показатель m_j имеет тенденцию b_j на интервале наблюдения $T=[1,tk]$ ».

Учитывая логику медицинского исследования, определим на втором уровне грануляции пространственно-темпоральную модель показателей здоровья пациента в следующем виде, объединяющую информационные гранулы первого и второго уровня для текущего момента времени

$$YB = \{y_{jt}, b_{jt}, j = 1, 2, \dots, mk, t = tk\},$$

которая определяет протоформу $P22: \text{for } tk \ m_j \text{ is } y_{jt} \ \& \ m_j \text{ is } b_j$, семантика которой представима пропозицией «для текущего момента времени tk значение показателя m_j является y_{jt} и его тенденция – b_j ».

Грануляция цифровой модели показателей здоровья пациента третьего уровня ориентирована на извлечение знаний о здоровье пациента агрегированных по множеству показателей и их тенденций. Для этих целей предлагается применить метод обобщения информационных гранул, включенных в пространственно-темпоральную модель. Мы рассматриваем обобщение как общую характеристику здоровья пациента, представленную в количественном и лингвистическом форматах.

Количественное обобщение информационных гранул является результатом агрегирования одноименных гранул и вычисления процента одноименных гранул в общем количестве показателей. Так для количественно-

го обобщения информационных гранул тенденций b_j или состояний y_{ji} применимы протоформы вида P31: $Qn m_j$ is b_j и P32: $Qn m_j$ is y_{ji} , примером пропозиции для последней протоформы является утверждение «30% показателей являются очень высокими».

Лингвистическое обобщение информационных гранул предполагает создание лингвистической шкалы, определенной на интервале от 0 до 1 (или от 0% до 100%). Такая лингвистическая шкала с градациями, построенными на основе медицинских знаний $Z2 \subset Z$ позволяет перейти от количественных характеристик к качественным оценкам выраженности проблем со здоровьем. В качестве наименования градаций таких шкал может быть использовано терм-множество $Sq = \{\text{«все»}, \text{«большинство»}, \text{«половина»}, \text{«меньшинство»}, \text{«ни одного»}\}$.

Тогда результат лингвистического обобщения можно задать в виде протоформ P33: $Ql m_j$ is b_j и P34: $Ql m_j$ is y_{ji} , для которых несложно сгенерировать пропозиции «Все показатели имеют тенденцию стабильность», «Большинство показателей имеют отклонения от нормы».

Агрегация информационных гранул на четвертом уровне предназначена для создания трех гранул, характеризующих отсутствие проблем, наличие проблем и наличие серьезных проблем со здоровьем, требующих срочной медицинской помощи. Для получения таких гранул наиболее адекватным методом является система логических правил, построенная на основе медицинских знаний $Z3 \subset Z$.

Все предложенные протоформы, полученные на четырех уровнях градуляции, содержат знания о состоянии и тенденциях здоровья, полученных по цифровой модели показателей пациента и являются источником информации для генерации цифровых пациент-ориентированных рекомендаций. Пропозиции, создаваемые на основе рассмотренных протоформ, естественным образом образуют компонент Es цифровой пациент-ориентированной рекомендации R , который в свою очередь определяет содержание компонент EsG и $Plan$, для чего необходимо использовать системы логического вывода, построенные с помощью медицинских знаний $Z4 \subset Z$.

Заключение

Вовлекая пациента в управление, мониторинг и принятие решений по улучшению своего здоровья, используя пациент-ориентированные системы и цифровые пациент-ориентированные рекомендации можно достичь большего эффекта как в направлении сохранения трудоспособного населения, профилактики заболеваний и оптимизации затрат на здравоохранение в целом. В статье обосновывается актуальность пациент-ориентированных систем и приводится их определение как рекоменда-

тельных систем по управлению здоровьем, основанных на знаниях. Для представления знаний разработаны модели здоровья пациента в рамках принципов доказательной медицины с использованием теории грануляции и гранулярных моделей в виде интервалов, нечетких множеств, правил логического вывода, лингвистических шкал и протоформ. Предложенная структура цифровых пациент-ориентированных рекомендаций соответствует модели ЧПК (Что рекомендуется сделать, Почему это рекомендуется сделать, Как эффективнее выполнить рекомендации) и определяет результат работы пациент-ориентированных систем. Для генерации цифровых пациент-ориентированных рекомендаций по цифровой модели показателей здоровья разработан новый сценарий, извлекающий информационные гранулы на четырех уровнях. Дальнейшая работа будет сфокусирована на разработке экспериментальной версии пациент-ориентированной системы.

Список литературы

- [Авдеев, 2019] Авдеев И.А. Порядок разработки, структура и содержание клинических рекомендаций (протоколов лечения), 2019. https://xn----7sbahcmgafaski8a2afibqaiuxe4dxd.xn--p1ai/publ/metodicheskie_materialy/porjadok_razrabotki_struktura_i_soderzhanie_klinicheskikh_rekomendacij_protokolov_lechenija/26-1-0-983.
- [Афанасьева и др., 2016] Афанасьева Т.В., Мошкин В.С., Наместников А.М., Тимина И.А., Ярушкина Н.Г. Онтологический и нечеткий анализ слабоструктурированных информационных ресурсов. – Ульяновск, 2016. – 130 с.
- [Верткин, 2021] Верткин А.Л., Седякина Ю.В., Погонин А.В., Романенко И.И. «Гипократ» – система поддержки принятия врачебных решений для первичного звена по раннему выявлению социально-значимых заболеваний. Медицинский алфавит. – 2021;(7):11-14. – <https://doi.org/10.33667/2078-5631-2021-7-11-14>.
- [Вяткина, 2019] Вяткина Н.А. Уровень медицинской грамотности российских пациентов в оценке врачей // Сибирские исторические исследования. – 2019. – 4. – С. 162-179. – <https://cyberleninka.ru/article/n/uroven-meditsinskoy-gramotnosti-rossijskih-patsientov-v-otsenke-vrachey>.
- [Гусев, 2017] Гусев А. В., Зарубина Т. В. Поддержка принятия врачебных решений в медицинских информационных системах медицинской организации // Врач и ИТ. – 2017. – № 2. – С. 60-72.
- [Клинические рекомендации, 2020] Клинические рекомендации (типовая форма). Приказ Минздрава России от 23 июня 2020 г. N 617Н, Приложение 2, изменено с 4 августа 2020 г. 2020. Доступно по адресу: <https://base.garant.ru/72240714/f7ee959fd36b5699076b35abf4f52c5c>.
- [Мачильская, 2016] Мачильская О.В. Факторы, определяющие приверженность к лечению больных артериальной гипертензией (обзор литературы) // Кардиология и сердечно-сосудистая хирургия. – 2016. – 9 (3). – С. 55-65.

- [Шальнова и др. 2018]** Шальнова С.А., и др. Какие факторы влияют на контроль артериальной гипертензии в России // Кардиоваскулярная терапия и профилактика. – 2018. – 17 (4). – С. 53-60. – <https://doi.org/10.15829/1728-8800-2018-4-53-60>.
- [Ambika, 2015]** Ambika M., Latha, K. (2015). Intelligence Based Recommendation System for Healthcare: A Patient centred Framework. – P. 245-255. – 10.18797/CAASR/ICIET/2015/11/27/19.
- [Bader, 2022]** Bader M, Zheng L, Rao D, Shiyanbola O, Myers L, Davis T, O'Leary C, McKee M, Wolf M, Assaf AR. Towards a more patient-centered clinical trial process: A systematic review of interventions incorporating health literacy best practices. *Contemp Clin Trials*. 2022 May;116:106733. – Doi: 10.1016/j.cct.2022.106733. Epub 2022 Mar 15. PMID: 35301134; PMCID: PMC9196949.
- [Bouhissi, 2021]** Bouhissi, H.E., Adel, M., Ketam, A., & Salem, A.M. Towards an Efficient Knowledge-based Recommendation System. *IntelITSIS*. – 2021.
- [De Croon, 2021]** De Croon R., Van Houdt L., Htun NN., Štiglic G., Vanden Abeele V., Verbert K. Health Recommender Systems: Systematic Review // *J Med Internet Res*. 2021 Jun 29;23(6):e18035. – Doi: 10.2196/18035. PMID: 34185014; PMCID: PMC8278303.
- [Jannach, 2011]** Jannach D., Zanker M., Felfernig A., Friedrich G. *Recommender Systems: An Introduction*. New York, NY, USA: Cambridge Univ. Press, 2011.
- [Gil, 2019]** Gil M., El Sherif R., Pluye M., Fung B. C. M., Grad R., Pluye P. Towards a Knowledge-Based Recommender System for Linking Electronic Patient Records With Continuing Medical Education Information at the Point of Care // in *IEEE Access*. – 2019. – Vol. 7. – P. 15955-15966. – Doi: 10.1109/ACCESS.2019.2894421.
- [Kleinsinger, 2018]** Kleinsinger F. The Unmet Challenge of Medication Nonadherence // *Perm J*. – 2018. – 22. – P. 18-033. – Doi: 10.7812/TPP/18-033. PMID: 30005722; PMCID: PMC6045499.
- [Kobriniskii, 2019]** Kobriniskii B.A., Grigoriev O.G., Molodchenkov A.I., Smirnov I.V., Blagosklonov N.A. Artificial Intelligence Technologies Application for Personal Health Management №25 *IFAC-PapersOnLine*. – 2019. – 52. – 70-74/10.1016/j.ifacol.2019.12.448.
- [Liu, 2021]** Liu W, Yin L, Wang C, Liu F, Ni Z. Multitask Healthcare Management Recommendation System Leveraging Knowledge Graph. *J Healthc Eng*. 2021 Nov 5;2021:1233483. – Doi: 10.1155/2021/1233483. PMID: 34777727; PMCID: PMC8589481.
- [Pedrycz, 2018]** Pedrycz W. Granular Computing for Data Analytics: A Manifesto of Human-Centric Computing // *IEEE/CAA J. Autom. Sinica*. – 2018. – Vol. 5 (6). – P. 1025-1034. – Doi: 10.1109/JAS.2018.7511213.
- [Ricci, 2011]** Ricci F., Rokach L., Shapira B., B. Kantor P. *Recommender Systems Handbook*. New York, NY, USA: Springer, 2011.
- [Sutton, 2020]** Sutton R.T., Pincock D., Baumgart D.C. et al. An overview of clinical decision support systems: benefits, risks, and strategies for success. *npj Digit. Med*. – 2020. – 3, 17. – <https://doi.org/10.1038/s41746-020-0221-y>.

- [**Tran, 2021**] Tran T.N.T., Felfernig A., Trattner C. et al. Recommender systems in the healthcare domain: state-of-the-art and research issues // J Intell Inf Syst. – 2021. – 57. – P. 171-201. – <https://doi.org/10.1007/s10844-020-00633-6>.
- [**Zadeh 1997**] Zadeh L.A. Toward a Theory of Fuzzy Information Granulation and its Centrality in Human Reasoning and Fuzzy Logic // Fuzzy Sets and Systems. – 1997. – Vol. 90. – P.111-127.
- [**Zadeh, 2002**] Zadeh L. A prototype-centered approach to adding deduction capabilities to search engines – the concept of a protoform // Annual Meeting of the North American Fuzzy Information Processing Society (NAFIPS 2002). – 2002. – P. 523-525.
- [**Zadeh, 2006**] Zadeh L. Generalized theory of uncertainty (GTU) – principal concepts and ideas // Computational statistic & Data analysis. – 2006. – Vol. 51. – P. 15-46.
- [**Yao, 2005**] Yao Y. Perspectives of granular computing // In: Proceedings of 2005 IEEE International Conference on Granular Computing. 1, IEEE, Beijing, 2005. – P. 85-90.

УДК 004.9

МЕТОД ИНТЕЛЛЕКТУАЛЬНОЙ ПОДДЕРЖКИ ПРИНЯТИЯ ЛОГИСТИЧЕСКИХ РЕШЕНИЙ НА ОСНОВЕ ГЕНЕТИЧЕСКОЙ КЛАСТЕРИЗАЦИИ И НЕЧЕТКОГО МОДЕЛИРОВАНИЯ*

В.В. Борисов (*vbor67@mail.ru*)

А.В. Рязанов (*ballack.1391@mail.ru*)

Филиал ФГБОУ ВО «Национальный исследовательский университет «МЭИ» в г. Смоленске

А.В. Бобряков (*avbob@mail.ru*)

ФГБОУ ВО «Национальный исследовательский университет «МЭИ», Москва

В работе рассмотрен метод интеллектуальной поддержки принятия логистических решений на основе генетической кластеризации и нечеткого моделирования. Выполнена постановка задачи исследования и представлено решение взаимосвязанных задач разбиения территории логистического обслуживания на зоны, определения требуемого количества транспортных средств при распределении логистических заказов по зонам, назначения транспортных средств для выполнения логистических заказов. Использование предлагаемого метода (на примере онлайн-заказов транспортных средств) позволяет повысить качество и оперативность принимаемых логистических решений.

Ключевые слова: зональное разбиение территории, генетическая кластеризация, распределение логистических заказов, нечеткие модели.

Введение

В настоящее время для различных крупных организаций и компаний (в том числе таких, как Яндекс, Google, Uber) существенно повышается роль принятия качественных и оперативных логистических решений при управлении заказами, ресурсами, транспортировкой. При этом основными

* Исследование выполнено за счет гранта Российского научного фонда № 22-61-00096, <https://rscf.ru/project/22-61-00096/>.

задачами поддержки принятия логистических решений являются следующие: зональное разбиение территорий; определение требуемых ресурсов (транспортных средств) для выполнения логистических заказов в территориальных зонах; распределение логистических заказов по территориальным зонам; назначение транспортных средств на выполнение логистических заказов в этих зонах.

Для решения каждой из указанных задач используются различные подходы и методы. Так, например, для зонального разбиения территорий хорошо зарекомендовал себя подход на основе построения диаграмм Вороного, а для распределения логистических заказов и назначения транспортных средств для выполнения заказов – подход, основанный на различных разновидностях метода Г. Куна (венгерского метода) [Воронцов, 2019], [Ширяев и др., 2021].

Вместе с тем, используемые подходы и методы не в достаточной степени учитывают:

- взаимообусловленность, конвергентность, асинхронную цикличность выполнения и изменения параметров всей совокупности логистических задач, начиная от зонального разбиения территорий, заканчивая назначением конкретных транспортных средств на выполнение логистических заказов в территориальных зонах;
- доминирование качественных, недостаточно хорошо определенных факторов;
- специфику реализации логистических процессов в условиях неполноты и неопределенности информации о территориальных зонах, логистических заказах, состоянии транспортных средств и стратегиях их применения;
- субъективный и, зачастую, несогласованный характер показателей и критериев оценивания принимаемых логистических решений;
- динамичное изменение характеристик территориальных объектов в зонах, логистических заказов, транспортных средств и внешних факторов.

Эти особенности позволяют обосновать целесообразность применения для решения этих задач интеллектуальных методов и моделей, а также их гибридизацию, в том числе, методов генетической кластеризации и основанных на них способов зонального разбиения территорий, а также нечеткого логического подхода к оцениванию логистических решений и базирующихся на нем модификаций метода Г. Куна для распределения логистических заказов по территориальным зонам и назначения транспортных средств на их выполнение.

1. Постановка задачи исследования

Комплексная задача интеллектуальной поддержки принятия логистических решений включает в себя следующие последовательно выполняемые исследовательские задачи:

- разбиение территории логистического обслуживания на зоны;
- определение требуемого количества транспортных средств при распределении логистических заказов по зонам;
- назначение транспортных средств для выполнения логистических заказов.

Выполним формализованное представление и постановку этих взаимосвязанных задач исследования.

1) Зональное разбиение территории логистического обслуживания представим следующим образом:

$$R = \{R_i \mid i = 1, \dots, I\},$$
$$R_i = \{r_{n_i} \mid n_i = 1, \dots, N_i\},$$

где R – совокупность зональных разбиений территории; R_i – зональное разбиение территории для i -го интервала времени (например, для i -го часа суток); I – количество зональных разбиений (для рассматриваемого примера $I = 24$); r_{n_i} – отдельная зона зонального разбиения R_i ; N_i – число зон зонального разбиения R_i .

Каждое зональное разбиение R_i ($i = 1, \dots, I$) задается числом N_i зон зонального разбиения.

2) К каждой зоне r_{n_i} ($n_i = 1, \dots, N_i$) зонального разбиения R_i ($i = 1, \dots, I$) относится соответствующее подмножество H_{n_i} территориальных объектов (зданий, сооружений) $h_{j_i}^{(n_i)}$:

$$\forall R_i : H = \{H_{n_i} \mid n_i = 1, \dots, N_i\},$$
$$H_{n_i} = \{h_j^{(n_i)} \mid j = 1, \dots, J_{n_i}\},$$

где H – общее число территориальных объектов; H_{n_i} – подмножество территориальных объектов $h_{j_i}^{(n_i)}$, относящееся к зоне r_{n_i} ; J_{n_i} – количество территориальных объектов в зоне r_{n_i} .

Каждая зона r_{n_i} ($n_i = 1, \dots, N_i$) характеризуется следующими показателями:

- количество J_{n_i} территориальных объектов $h_{k_i}^{(n_i)}$;
- координаты центра зоны;

- площадь зоны;
- смежные зоны;
- число транспортных средств в зоне;
- число заказов, поступивших из зоны.

3) Логистические заказы:

$$Z = \{Z_i \mid i = 1, \dots, K\},$$

$$Z_i = \{Z_{n_i}^{(i)} \mid n_i = 1, \dots, N_i\},$$

$$Z_{n_i}^{(i)} = \{z_k^{(n_i \rightarrow m_i)} \mid k = 1, \dots, K_{n_i}\}, \quad n_i, m_i \in R_i,$$

где Z – множество логистических заказов, поступивших в течение всего времени, соответствующего количеству I зональных разбиений территории; Z_i – подмножество логистических заказов, соответствующих зональному разбиению R_i территории; $Z_{n_i}^{(i)}$ – подмножество логистических заказов, поступивших из зоны r_{n_i} ; $z_k^{(n_i \rightarrow m_i)}$ – логистический заказ из зоны r_{n_i} в зону r_{m_i} (в частном случае $n_i = m_i$); K_{n_i} – число логистических заказов, поступивших из зоны r_{n_i} .

Каждый логистический заказ $z_k^{(n_i \rightarrow m_i)}$ ($k = 1, \dots, K_{n_i}$) характеризуется следующими показателями:

- зона r_{n_i} поступления заказа;
- зона r_{m_i} окончания заказа;
- территориальный объект, из которого поступил логистический заказ;
- территориальный объект, на который выполняется заказ;
- характеристики заказа (детское кресло, некурящий водитель и др.).

4) Транспортные средства:

$$\forall A_i \subseteq A, \quad i = 1, \dots, I,$$

$$A_i = \{A_{n_i}^{(i)} \mid n_i = 1, \dots, N_i\},$$

$$A_{n_i}^{(i)} = \{a_l^{(n_i)} \mid l = 1, \dots, L_{n_i}\},$$

где A – множество транспортных средств; A_i – множество транспортных средств, готовых выполнить логистические заказы для зонального разбиения R_i ; $A_{n_i}^{(i)}$ – подмножество транспортных средств, находящихся в зоне r_{n_i} ; $a_l^{(n_i)}$ – транспортное средство, находящихся в зоне r_{n_i} ; L_{n_i} – количество транспортных средств, находящихся в зоне r_{n_i} .

Каждое транспортное средство $a_i^{(n_l)}$ ($l=1, \dots, L_{n_l}$) характеризуется следующими показателями:

- пробегом без заказов;
- степенью выполнения дневной нормы;
- заработком на текущий момент;
- выполняемым в данный момент заказом;
- зоной, в которой находится;
- зоной куда направляется, если есть текущий заказ;
- координатой, где сейчас находится.

С учетом предложенного выше формализованного представления выполним постановку каждой из перечисленных в начале данного подраздела исследовательских задач.

- необходимо реализовать метод, обеспечивающий зональное разбиение территории и распределение логистических заказов с учетом полученного разбиения, выбранной стратегии подбора транспортных средств и назначения логистических заказов;
- для реализации шагов метода необходимо предложить способ зонального разбиения территории обслуживания, способ оценки требуемых ресурсов по зонам на основе скользящего временного окна, способ распределения логистических заказов с учетом их назначений;
- требуется провести оценку качества логистических решений на основе предлагаемого метода.

2. Разбиение территории логистического обслуживания на зоны

Разбиение территории логистического обслуживания на зоны проводится с использованием,

- во-первых, генетической кластеризации территориальных объектов относительно центров зон;
- во-вторых, формирования выпуклых оболочек этих зон с учетом частоты и времени заказов от территориальных объектов, а также геопространственных особенностей их размещения.

Процедура генетической кластеризации территориальных объектов относительно центров зон проводится для каждого часа в сутках для того, чтобы учесть динамику логистических заказов для разных временных диапазонов и построить оптимальное их покрытие. Суть данной задачи заключается в построении кластеризаций территории для каждого часа суток методом k -средних, с учетом наилучшего количества (с точки зре-

ния показателя качества кластеризации) кластеров, и в подстраивании границ этих зон с помощью генетического алгоритма, учитывающего такие факторы, как геопространственные особенности внутри полученных зон, их размеры и доходность логистических заказов.

Качество решения задачи разбиения территории логистического обслуживания на зоны предлагается оценивать на основе минимизации среднего времени T_{med} , затрачиваемого при подъезде транспортных средств к логистическим заказам, за счет нахождения и выстраивания зон обслуживания вокруг областей сгущения заказов, минимизации полученных площадей.

$$\begin{aligned}
 & T_{med} \xrightarrow{*} \min, \\
 & T_{med} \xrightarrow{\{R_i | i=1, \dots, I\}, \{Z_{n_i}^{(i)} | n_i=1, \dots, N_i\}} \min, \\
 & T_{med} \xrightarrow{R_i = f(Z_{n_i}^{(i)}, H_{n_i}^{(i)}, A_{n_i}^{(i)})} \min, \\
 & S \leq S_{\min}.
 \end{aligned}$$

При этом наилучшее зональное разбиение территории проводится для каждого часа суток с использованием статистических данных для определения областей «сгущения» заказов [Аверченков, 2021], [Вирсански, 2020], [Гладков и др., 2010], [Мышкис, 2021], [Ryazanov et al., 2018].

3. Определение требуемого количества транспортных средств при распределении логистических заказов по зонам

Суть этой задачи заключается в определении минимально необходимого числа водителей для каждой зоны в рамках каждого временного диапазона. Для этого анализируется среднее время выполнения заказа каждой зоны в рамках временного диапазона, и ищется максимальное количество заказов. Это количество и считается минимально необходимым количеством транспортных средств для выполнения логистических заказов в заданной зоне в рамках временного диапазона.

$$t_{window} = \frac{\sum_{i=1}^n T_{n_i}^{(i)}}{Z_{n_i}^{(i)}},$$

$$L_{n_i} = \varphi\left(Z_{n_i}^{(i)}, t_{window}\right),$$

где $T_{n_i}^{(i)}$ – время выполнения i -го заказа с момента начала до момента завершения, t_{window} – диапазон временного «окна».

4. Назначение транспортных средств для выполнения логистических заказов

Задача распределения заказов на обслуживание клиентов использует представление в виде двудольного графа $G = (Z, A)$, где $Z = \{z_1, \dots, z_n\}$ – множество поступающих заказов и $A = \{a_1, \dots, a_m\}$ – множество транспортных средств, готовых их выполнить, а $Y = \{y_{ij}\}$, $i = \overline{1, n}$, $j = \overline{1, m}$ – множество ребер, связывающих вершины из множества Z с вершинами множества A .

В соответствии с алгоритмом Г. Куна при распределении заказов необходимо из всего множества возможных заказов $\gamma = \sum_{i=1}^n \gamma_i^Z$ или

$\gamma = \sum_{j=1}^m \gamma_j^A$ выбрать такую совокупность бинарных отношений между вер-

шинами графа (заказ–автомобиль), которая в наилучшей степени удовлетворяла бы заданному интегральному критерию качества $k_{ij} \in K$, который может быть поставлен в соответствие каждому ребру из Y . При этом $k_{ij} = f(k_{ij}^1, k_{ij}^2, \dots, k_{ij}^p)$, компоненты которого могут характеризоваться удаленностью от места назначения, типом автомобиля, процентом выполнения дневного плана, типом клиента и другими показателями.

Таким образом, задача распределения заказов в каждой зоне сводится к нахождению такого бинарного отношения вершин множества Z с вершинами множества A так, чтобы каждой вершине z_i соответствовала только одна вершина a_j и наоборот.

При этом необходимо распределить полученные заказы (множество Z) между транспортными средствами таким образом, чтобы достичь максимальной эффективности F при их выполнении:

$$F = \sum_{i=1}^n \sum_{j=1}^m k_{i,j} x_{i,j} \rightarrow \max,$$

$$F = \bigoplus_{i=1}^n (\max_j (\tilde{k}_{i,j} \otimes \tilde{x}_{i,j})) \rightarrow \max$$

при ограничениях на количество:

- заказов, назначенных к исполнению логистическими средствами:

$$\sum_{i=1}^m x_{i,j} \leq 1, i = 1, \dots, m,$$

- транспортных средств, получивших к исполнению данный логистический заказ:

$$\sum_{j=1}^n x_{i,j} \leq 1, j = 1, \dots, n,$$

где $k_{i,j}$ – интегральный критерий эффективности, учитывающий p весовых локальных коэффициентов для i -го транспортного средства при выполнении j -го заказа; $x_{i,j}$ – элемент искомой матрицы назначений.

Другой критерий качества логистических решений – максимизация числа выполненных заказов:

$$Z_{n_i}^{(i)} \rightarrow Z_{n_i}^{(i)}$$

где $Z_{n_i}^{(i)}$ – общее количество заказов, $Z_{n_i}^{(i)}$ – количество выполненных заказов [Жежера, 2021], [Рязанов, 2017], [Рязанов и др., 2018], [Рязанов и др., 2019], [Сонькин, 2009].

Возможны различные стратегии назначения транспортных средств для выполнения логистических заказов.

Стратегия 1. Максимизация доходов логистических средств

$$D_1 \xrightarrow{A_{n_i}^1 = f(P_1^{(i)}, \dots, P_{n_i}^{(i)})} \max,$$

где $P_{n_i}^{(i)}$ – суммарный доход транспортного средства за i -й период времени.

Стратегия 2. Минимизация пробега логистических средств без заказов

$$D_2 \xrightarrow{A_{n_i}^2 = f(W_1^{(i)}, \dots, W_{n_i}^{(i)})} \min,$$

где $w_{n_i}^{(i)}$ – суммарный пробег транспортного средства за i -й период времени без заказа.

Стратегия 3. Равномерное распределение доходов логистических средств

$$\Delta D_3 \xrightarrow{A_{n_i}^3 = f(P_1^{(i)}, \dots, P_{n_i}^{(i)})} \min.$$

При этом для выбора наиболее подходящего транспортного средства также учитывается назначение заказов.

С учетом обоснованных стратегий распределения, назначений логистических заказов и характеристик транспортных средств строится каскадная нечеткая продукционная модель, которая служит для оценки степени соответствия логистического средства для выполнения логистического заказа [Борисов и др., 2021].

По результатам проведенных экспериментов качество логистических решений с использованием предлагаемого метода (по сравнению с известными инструментами онлайн-заказов транспортных средств) для стратегии максимизации доходов удастся повысить в среднем на 11,3%, для стратегии стратегии минимизации пробега – в среднем на 9,0% и для стратегии равномерного распределения доходов – в среднем на 7,4%.

Заключение

В статье рассмотрен предлагаемый метод интеллектуальной поддержки принятия логистических решений на основе генетической кластеризации и нечеткого моделирования. Метод основан на предварительном зонном разбиении территории, процедура которого реализуется с использованием усовершенствованного алгоритма генетической кластеризации территориальных объектов. Используемый в предлагаемом методе способ распределения логистических заказов представляет собой модификацию алгоритма Г. Куна, который использует расширенный набор компонентов критериев отбора (для каждого транспортного средства) и включает в себя совокупность как характеристик транспортных средств, так и параметров, характеризующих свойства разделяемых зон. Использование предлагаемого метода (на примере онлайн-заказов транспортных средств) позволяет повысить качество и оперативность принимаемых логистических решений.

Список литературы

- [**Ryazanov et al., 2018**] Ryazanov A., Borisov V. Method of Partitioning the Territory to Logistic Solutions Support Based on Genetic Clustering // Proceedings of the 29th DAAAM International Symposium / B. Katalinic (Ed.). Published by DAAAM International, Vienna, Austria, 2018. – P. 961-965.
- [**Аверченков, 2021**] Казаков П.В., Аверченков, В.И. Эволюционное моделирование и его применение: монография. – 4-е изд., стер. – М.: ФЛИНТА, 2021. – 200 с.
- [**Вирсански, 2020**] Вирсански Э. Генетические алгоритмы на Python / под. ред. Д.А. Мовчан. – ДМК-Пресс, 2020.
- [**Воронцов, 2019**] Воронцов К.В. Курс «Машинное обучение». – <https://yag.ru/2020/05/07/vorontsov-kurs-mashinnoe-obuchenie-2019-shkola-analiza-dannyh/>.
- [**Гладков и др., 2010**] Гладков Л.А., Курейчик В.В., Курейчик В.М. Генетические алгоритмы / под ред. В.М. Курейчика. – 2-е изд., исправл. и доп. – М.: Физматлит, 2010.
- [**Жежера, 2021**] Жежера Н.И. Объекты систем автоматического управления. – М.: Инфра-Инженерия, 2021. – 244 с.
- [**Мышкис, 2021**] Мышкис А.Д. Прикладная математика для инженеров: Специальные курсы. Высшая математика в программе прикладных наук. – М.: Ленанд, 2021. – 648 с.

- [Рязанов, 2017] Рязанов А.В. Способ распределения логистических заказов на основе генетического алгоритма и нечеткого оценивания // Нейрокомпьютеры: разработка, применение. – 2017. – № 7. – С. 32-38.
- [Рязанов и др., 2018] Рязанов А.В., Борисов В.В. Интеллектуальный способ зонального разбиения территории для поддержки логистических решений // Нейрокомпьютеры: разработка, применение. 2018. №4. – С. 11-17.
- [Рязанов и др., 2019] Рязанов А.В., Борисов В.В. Метод и программные средства интеллектуальной поддержки принятия логистических решений // Программные продукты и системы. – 2019. – Т. 32, № 4. – С. 673-681.
- [Сонькин, 2009] Сонькин Д.М. Адаптивный алгоритм распределения заказов на обслуживание автомобилями такси // Известия Томского политехнического университета. – 2009. – Т. 315, № 5. – С. 65-69.
- [Ширяев и др., 2021] Ширяев Е.В., Ширяев В.И. Принятие решений. Математические основы. Статические задачи. – М.: Едиториал УРСС, 2021. – 208 с.
- [Борисов В.В. и др., 2021] Борисов В.В., Луферова Е.А. Метод прецедентного обучения нечетких моделей на основе нечеткого байесовского подхода // Сборник научных трудов X Международной научно-технической конференции Интегрированные модели и мягкие вычисления в искусственном интеллекте (ИММВ-2021), Коломна, 17-20 мая 2021 г.). В 2-х т. Т. 1. – С. 233-240. – Смоленск: Универсум, 2021. – 449 с.

УДК 007.52:004.896: 004:942

БАЗОВЫЕ ТРЕНДЫ ДЕЦЕНТРАЛИЗОВАННОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

В.И. Городецкий (*vladim.gorodetsky@gmail.com*)
АО “ЭВРИКА”, Санкт-Петербург

Анализ современных трендов и передовых концепций в области искусственного интеллекта показывает возрастающую роль его децентрализованных технологий в ИТ-приложениях нового поколения. В работе проведен анализ таких приложений, дан анализ современных достижений в области децентрализованного ИИ и самоорганизации, способных поддержать практическую реализацию таких приложений, а также сформулирован аналог дорожной карты соответствующего развития ИИ на ближайшую перспективу.

Ключевые слова: децентрализованный ИИ, системы сетевой структуры, самоорганизация, парные взаимодействия, децентрализованное машинное обучение, групповое управление.

Введение

Новая волна интереса со стороны индустриального сообщества к использованию технологий искусственного интеллекта (ИИ) оказывает сильное влияние на приоритеты и тренды его развития. Современное развитие теоретического и технологического базиса ИИ ограничено, в основном, централизованными архитектурами и *stand-alone*-приложениями в области машинного обучения в интересах задач компьютерного зрения, обработки речи и голосовых помощников, естественного языка, различных задач классификации и предсказания в рамках бизнес-проблем различного назначения. ИИ-приложения других классов встречаются заметно реже и обычно на уровне прототипов.

Однако потребности ИТ в использовании новейших технологий ИИ постоянно растут, и это один из заметных трендов ИТ-индустрии, причем лидером здесь является децентрализованный ИИ [Сао, 2022]. Обусловлено это особенностями большей части современных приложений, которые обычно состоят их большого числа автономных мобильных объектов, которые интенсивно взаимодействуют при совместном решении задач. К ним относятся новые приложения Интернета вещей, управление в груп-

пах мобильных беспилотных объектов. Глобализация в индустрии бизнеса также ведет к возрастанию роли распределенных и децентрализованных архитектур. Существуют и скорее всего, будут появляться новые классы приложений, в которых потребуются решать задачи децентрализованного группового управления в реальном времени. Военные приложения, космос, вредные среды, природные катастрофы и другие области – это источники новых приложений и новых требований к возможностям ИИ.

С формальной точки зрения все эти системы объединяет то, что они работают в коммуникационной среде с динамической топологией, и потому каждое такое приложение представляет собой динамическую сеть.

В последние несколько лет в ИТ появились новые проекты и новые парадигмы организации вычислений в динамических сетях, которые, с одной стороны, опираются на достижения ИИ, а с другой – задают новые ориентиры и перспективы его развития. Многие авторы считают, что наиболее явно эти ориентиры представлены в архитектуре *периферийных вычислений*, в концепции *децентрализованного бизнеса* без посредников с р2р- и блокчейн-технологиями в основе, в новой версии веб, называемой *Web3*, а также в проекте под названием *метавселенная* [Сао, 2022].

Эти проекты уже получили определенное развитие, и ИТ-специалисты связывают с ними будущее ИТ-технологий и приложений нового поколения, а также полагают, что развитие ИИ в ближайшие годы будет определяться их потребностями. Ценность отмеченных проектов состоит в том, что, с одной стороны, они в концентрированной форме задают базовые требования к ИИ-технологиям ближайшего будущего, а с другой – являются источниками новых идей, которые будут стимулировать появление новых инструментов для разработки приложений ИТ нового поколения типа перечисленных выше, и даже сложнее.

В работе [Сао, 2022] на основании анализа новых ИТ-парадигм акцентируется внимание возрастающей важности децентрализованных технологиях ИИ. Цель данной работы – это сделать следующий шаг, а именно (1) выявить в этих парадигмах базовое множество трудных проблем, которые нуждаются в технологиях децентрализованного ИИ (ДИИ), (2) провести анализ результатов, которыми располагает ДИИ уже в настоящее время и (3) акцентировать внимание на важных задачах, к решению которых следует привлечь внимание специалистов ИИ в ближайшее время. Далее в разд. 1 приводятся краткие сведения о новых ИТ-проектах и парадигмах, указанных выше, в разд. 2 дается минимальная информация о многоагентных системах (МАС) и принципах управления на основе самоорганизации, которые формируют контекст, необходимый для понимания последующего материала, В разд. 3 перечисляются достижения в области ДИИ и самоорганизации, которые уже сейчас готовы к использованию.

В разд. 4 анализируются перспективные направления исследований в области ДИИ и самоорганизации, которые позволят существенно расширить области их практического использования, обеспечивая их вычислительную эффективность и отказоустойчивость. В Заключении резюмируются результаты работы.

1. Новые ИТ-парадигмы и требования к возможностям ИИ

Ниже даются краткие сведения о новых проектах, концепциях и разработках в области ИТ, которые по мнению специалистов определяют требования к уровню ИИ ближайшего будущего [Cao, 2022].

Периферийные вычисления. Это архитектура распределенных децентрализованных сетевых вычислений. В ней обработка данных производится как можно ближе к их источникам и потребителям результатов. Особое значение она имеет для мобильных сетей, поскольку перенос вычислений на периферию увеличивает скорость обработки данных и снижает задержки, обусловленные ограниченностью ресурсов мобильных устройств, включая энергопотребление [Zhang, 2022]. Системы, построенные на основе этой архитектуры, в общем случае могут иметь различные сочетания централизации и децентрализации. Отдельные локальные подсистемы могут использовать децентрализованную архитектуру, но при наличии иерархии в сети некоторые функции могут выполняться и в централизованном варианте. Подробное описание этой архитектуры и ее свойств можно найти [Cao, 2022, Zhang, 2022].

Децентрализованный бизнес. В этой концепции бизнес работает без посредников, т.е. на основе парных взаимодействий его участников. Его наиболее развитый вариант – это децентрализованный финансовый бизнес (DeFi). Он является альтернативой традиционному финансовому бизнесу и его инструментам. В нем все операции с финансовыми активами выполняются без посредников [Cao, 2022, Гидаспов, 2022].

DeFi манипулирует с *цифровыми активами* (DeFi-токенами), под которыми понимают сущности, возможно, абстрактные, которые имеют ценность на финансовом рынке. Одним из примеров цифровых активов являются криптовалюты. Другой пример – невзаимозаменяемые токены (англ. Non Fungible Token, NFT¹). Они аналогичны ценным бумагам, но являются цифровыми. Они существуют в своей экосистеме.

Важное понятие DeFi – это *цифровой кошелек*, а по сути – интерфейс пользователя для доступа к своим активам и управления ими. Еще одно понятие DeFi называется *смарт-контрактом*, под которым понимают

¹ Пример NFT – предметы цифрового искусства. Цифровое произведение Beeple, 5000 Days было продано на аукционе за 69 млн. долларов, см. <https://www.heverge.com/2021/3/11/22325054/beeple-christies-nft-sale-cost-everydays-69-million>

процедуру выполнения тех или иных действий в DeFi-экосистеме, например, действие по пересылке цифрового актива от одного участника рынка другому. Манипуляции с компонентами DeFi подчинены правилам, которые должны автоматически поддерживаться средствами его экосистемы. Эта поддержка выполняется с помощью протоколов парных взаимодействий. Примерами являются правила выполнения действий типа “генерация транзакций”, “проверка данных”, “хранение данных”. Эта цепочка операций DeFi выполняется без посредников.

В основу реализации DeFi-бизнеса положена технология блокчейна [Nasir, 2021]. Блокчейн – это цепочка цифровых блоков, следующих друг за другом (транзакций), связанных общим контекстом. Заметим, что применение технологии блокчейна не ограничивается хранением транзакций. Ее широко используют в других задачах, что обусловлено рядом свойств, которыми эта технология обладает. К ним относятся децентрализованное хранение и выполнение операций с цифровыми активами, прозрачность (доступ к деталям и к траектории транзакций), неизменность хранимых данных, отсутствие посредников (их роль выполняют протоколы консенсуса), анонимность (аутентификация пользователя без раскрытия его личности), возможность аудита, встроенная защита от атак и отказоустойчивость.

Из приведенного описания DeFi можно заключить, что парные взаимодействия и децентрализация в p2p-коммуникационной среде определяют существо требований, выдвигаемых ими по отношению к ИИ.

Концепция Web3 [Карелина, 2021]. Эта концепция имеет целью развитие всемирной паутины в направлении децентрализации хранения контента. В такой концепции ИТ-гиганты типа Google, Amazon, Apple и др. теряют монополию на контент и его контроль. Владелец контента в *Web3* хранит его на своей стороне, и потому этот контент защищен от внешней блокировки, что повышает уровень доверия к нему и уровень его безопасности, делает менее уязвимым перенос цифровых бизнесов типа DeFi в среду Интернет, расширяет возможности цифровой экономики на основе токенов как цифровых активов. Принято говорить, что *Web3* – это переход от текстов для человека к текстам для компьютеров, которые смогут их анализировать, делать заключения, использовать в машинном обучении и т.д. Очевидно, что в концепции *Web3* термин *децентрализация* является ключевым в части требуемых свойств ИТ- и ИИ-технологий.

Метавселенная (англ. metaverse). Этот проект расширяет понятие киберпространства, пополняя его цифровыми двойниками компонент и аспектов физического мира и связями между ними. Это приводит к созданию виртуального мира, параллельного физическому миру [Lee, 2021]. Судя по заявленным целям, проект готовит цифровой взрыв киберпространства. Его предшественниками являются виртуальные среды типа социальных сетей, видеоконференций, дополненной реальности и др.

В метавселенной люди физического мира взаимодействуют друг с другом и с этой средой через своих посредников – цифровых аватаров [Lee, 2021]. Создание приложений метавселенной проходит в три этапа:

- создание цифровых двойников объектов физического мира в виртуальной среде;
- ее заселение «цифровыми аборигенами» и развитие с их участием;
- взаимодействие и взаимное обогащение обоих миров при их параллельном существовании и использовании [Lee, 2021].

В соответствии с этой схемой, сначала создается некоторое множество цифровых двойников для ряда аспектов реального мира. На этом этапе их называют «теньями» аспектов реальности в виртуальном мире. Далее люди-представители реального мира через своих автаров-цифровых аборигенов создают связанные экосистемы, охватывая такие стороны физического мира, как наука, культура, экономика, законы, социальные нормы и т.д. Они создаются по аналогии с экосистемами физического мира. В начале развития метавселенной цифровые двойники слабо связаны с соответствующими физическими мирами, но со временем цифровые аборигены устанавливают связи внутри виртуального мира и с аналогичными компонентами физического мира, формируя тем самым постепенно виртуальный мир и физико-виртуальный мир метавселенной.

Взаимодействие миров выполняется с помощью данных. Данные физической среды от сенсоров, из социальных сетей, СМИ т.п. подаются на вход цифровых двойников, изменяя их состояния. Эти данные могут использоваться в разных целях, включая машинное обучение. Цифровые двойники могут генерировать модельные данные о реальном мире, пополняющие информацию о реальном мире, создавая таким способом более полную его картину и усиливая ее предсказательные способности.

Анализируя технологии ИИ, необходимые для создания метавселенной и ее использования, можно сделать вывод о том, что они объединяют в себе требования из списка, приведенного выше для описанных концепций.

2. Многоагентные технологии и самоорганизация: Общие сведения

Анализ требований к направлениям развития ИИ со стороны ИТ-приложений нового поколения, состав которых можно представить по материалам предыдущего раздела, целесообразно проводить, опираясь на, хотя бы, минимальные предположения о свойствах этих приложений, например, об архитектуре. Как отмечалось во введении, новые наиболее востребованные и важные классы ИТ-приложений обычно представляют собой сетевые структуры динамической топологии с большим числом узлов и связями разнообразной семантики. Эти сети характеризуются тем,

что разные их узлы обладают разной информацией, способны решать разные задачи, они интенсивно взаимодействуют друг с другом и внешней средой при совместном решении различных задач. В их программной реализации узлам сети обычно ставятся в соответствие (автономные) объекты, например, беспилотные летательные аппараты, кооперативные роботы, спутники в системе космического наблюдения и т.д. Для таких систем наиболее подходящей архитектурой и технологией разработки является архитектура и технология автономного агента и МАС. Это обусловлено тем, что концепция агента по определению рассматривает автономность и способность к проактивному поведению в качестве его базовых свойств. Еще одно важное свойство агента – это его интерактивность. Интерактивность определяется как способность агентов оказывать влияние друг на друга. «Из интерактивности и автономности вытекает способность группы агентов решать сложные задачи на основе побочных эффектов от скоординированных действий» [Ferber, 2014],

Из этого краткого перечисления свойств агента следует, что модель агента для поведения узлов сети и модель МАС для описания поведения сетевого объекта в целом удачно подходят для ИТ-приложений рассматриваемого класса.

В описанной архитектуре программный агент, представляющий тот или иной автономный объект приложения, с одной стороны, управляет *внутренним поведением* программных и/или аппаратных компонент «своего» узла сети в различных случаях использования. С другой стороны, этот программный агент является представителем «своего узла» в сети программных агентов, где его функция – это взаимодействие с агентами других узлов сети путем обмена сообщениями для координация поведения «своего узла» при совместном решении ими некоторой общей задачи. При этом в системах сетевой структуры обычно напрямую могут взаимодействовать только «соседние» узлы сети независимо того, определяется ли «соседство» структурой коммуникационных каналов между ними или, например, оверлейной сетью в случае программно-определяемой сети. Поэтому все вычисления в таких сетях выполняются на основе локальных взаимодействий и принципов самоорганизации.

Самоорганизация определяется как динамический процесс системы, реализуемый в ней без внешнего вмешательства на основе локальных взаимодействий ее объектов, который ведет к появлению и поддержанию структуры на множестве ее объектов. [Городецкий, 2012а]. Самоорганизующиеся системы обладают также рядом специфических свойств, к которым относятся автономность, глобальность порядка, возникающего за счет локальных взаимодействий, эмерджентное поведение, возможная неустойчивость, которая возникает без внешних воздействий, чувстви-

тельность к начальным состояниям и малым вариациям параметров со скачкообразной сменой состояний, множественность устойчивых состояний (аттракторов); адаптивность как способность менять поведение и структуру при изменении локальных входов, сложность поведения как следствие большого числом компонент.

Большинство разработанных прототипов самоорганизующихся систем, реализовано в архитектуре МАС. До сих пор МАС является безальтернативной архитектурой для программной реализации самоорганизующихся систем. В настоящее время развитие принципов и моделей самоорганизации происходит в рамках исследований в области МАС [Городецкий, 2012а, Di Marzo Serugendo, 2005], [Ye, 2016]).

3. Децентрализация и самоорганизация систем ИИ. Уровень современных достижений

В исследованиях по обозначенной тематике можно выделить две волны активности. Первая из них охватывает период с середины 1980-х и до конца 1990-х годов. В это время основная тематика таких исследований и разработок, которые финансировались агентством DARPA (США), были проблемы группового управления автономных агентов в общей миссии. Вторая волна относится к периоду 2002–2010 гг., и в ней основные акценты исследований касались двух ключевых проблем ДИИ, а именно проблем децентрализованного машинного обучения и проблем р2р-коммуникаций в сетях автономных агентов. Примерно с 2000 г. начались активные исследования и разработки в области самоорганизации как базового принципа адаптивного управления в крупномасштабных приложениях сетевой структуры. Активные исследования в этой области продолжались примерно до 2015 г. Можно утверждать, что четыре названные проблемы (групповое управление, децентрализованное машинное обучение, р2р-коммуникации и самоорганизация) в разные периоды были в фокусе внимания исследований, связанных с ДИИ. Рассмотрим кратко основные результаты, полученные к настоящему времени по четырём названным проблемам.

В области группового управления к середине 1990-х годов было предложено несколько теорий, однако только две из них заложили теоретический базис последующих и современных моделей и программных инструментов в области группового управления. Пионерской была работа [Cohen, 1991], в которой предложена "Теория общих намерений". Она формулирует базовые понятия и общие рамки, определяющие групповое поведение агентов и особенности их взаимодействия в этом поведении, а также принципы информационного обмена, который способен поддерживать уровень их ситуационной осведомленности, необходимый для децентрализованной координации их индивидуального поведения для дос-

тижения групповой цели. По-видимому, наиболее важный и практически весьма полезный результат этой теории – это протокол взаимодействия членов команды агентов, называемый *протоколом общих намерений* [Jennings, 1995], который используется агентами команды для согласования своих обязательств и групповых соглашений и который решает общие вопросы распределенной координации их поведения автономной миссии без вмешательства извне.

Другая теория, известная под названием "Теория общих планов" (*англ.* Shared Plans Theory), строится несколько иначе [Grosz, 1995]. Её базовыми понятиями являются групповой план и индивидуальные ментальные понятия автономных агентов. Этот групповой план, помимо множества действий отдельных агентов группы, согласованных с множеством условий (время, место, ресурсы и т.д.), содержит и инфраструктурные компоненты модели, преобразующие множество распределенных агентов в единую команду. Обе названные теории имеют строгое математическое обоснование, однако до сих пор их программные реализации ограничены разработками на уровне простейших прототипов.

В последующих разработках разные авторы для своих моделей использовали различные комбинации отдельных идей обеих теорий. Наиболее известны две такие модели, STEM [Tambe, 1997] и RETSINA [Sycara, 2003]. Инструментальная поддержка программной реализации модели STEM выполняется средой Teamcore [Tambe, 1997, Tambe, 1999]. В ней архитектура программного агента, управляющего поведением агента, разделяется на две части. Одна из них является предметно зависимой, а другая – предметно независимой. Предметно независимая часть агента называется *teamcore-агент*. Она играет роль «обёртки» (*англ.* wrapper) для предметно зависимой его части. Обертка отвечает за внешнее поведение агента и наделяет его способностью к командной работе. Заметим, эта продуктивная идея получила развитие в разных работах.

Модель RETSINA [Sycara, 2003], имеет архитектуру, которая эксплуатирует, главным образом, теорию общих планов. В ее программной системе выделяется агент, который называется *кооперативным интерфейсным агентом*. Он приводит к централизации группового управления. В автономной миссии это решение может оказаться критическим из-за отсутствия отказоустойчивости.

Обе модели и поддерживающие их инструментарии в течение долгого времени рассматривались в качестве мировых лидеров в области группового управления, но обе разработки были закрыты к началу 2000-х годов, поскольку модели, предложенные в них, оказались непригодными для практики из-за их непреодолимой вычислительной сложности.

В последующий период (до 2010 г.) наблюдался застой в развитии теории и практики группового управления [Geihs, 2020], когда исследователи пытались адаптировать описанные теоретические модели к практическим потребностям. К числу удачных моделей этого периода следует отнести модель ВІТЕ, предложенную в [Kaminka, 2005]. В ней индивидуальное поведение агентов команды и групповое управление моделируются тремя структурами. Первая – это иерархическая структура задач команды агентов (структурированный план их действий). Вторая структура описывает структуру агентов и их подгрупп, которые назначены на решение отдельных задач миссии, описанных в первой структуре. Третья структура в явном виде описывает коммуникации и взаимодействия агентов в процессе распределённой координации поведения агентов. Эта модель существенно упрощает классические модели [Cohen, 1991, Grosz, 1995], в которых модель сценария должна выводиться динамически. Но и модель ВІТЕ также обладает большим недостатком. Авторы отмечают, что существование процесса автоматизации группового управления состоит в том, чтобы обеспечить автоматическое управление распределённым исполнением сценария в соответствии с некоторым стандартным протоколом и эта цель в модели ВІТЕ не достигнута. Эта проблема решена в работе [Gorodetsky, 2020].

Период с 2002 по 2020 гг. характеризуется активными исследованиями в области децентрализованного ИИ в задачах кластерного анализа и в задачах обучения классификации, хотя справедливости ради стоит отметить, что в США работы по децентрализованному машинному обучению на множестве распределённых данных были начаты еще в начале 1990-х годов. Например, интересные теоретические результаты, доведенные до практического использования, были получены в работах [Chan, 1999, Prodromidis, 2000]. Авторы этих работ уже тогда решали задачу децентрализованного обучения обнаружению фальшивых транзакций в группе банков США, которые не соглашались предоставить свои данные в распоряжение специалистов по машинному обучению, но согласились на то, что обучение будет проведено распределёнными агентами команды с использованием локальных данных каждого банка в децентрализованном варианте) с последующим использованием правил обнаружения фальшивых транзакций, полученных на локальных данных, и метаданных. Метод, который был разработан авторами этих работ, оказался успешным и использовался уже тогда на практике.

В период (2002–2006) гг. был выполнен новаторский проект Европейской программы FP6-IST под названием *KD-Ubiq: A blueprint for ubiquitous knowledge discovery systems*. В этом проекте исследовалась непростая проблема децентрализованного извлечения связей и зависимостей из распределённых данных и децентрализованных алгоритмов машинного обу-

чения на основе таких данных с акцентом на сохранение их конфиденциальности. Результаты этого проекта были опубликованы достаточно полно в книге [May, 2010]. Отдельные результаты, которые до сих пор сохраняют свою актуальность и практическую ценность, опубликованы в [Datta, 2006, Wolff, 2004]. В частности, в них были предложены протоколы децентрализованного вычисления математического ожидания, а также приближенный алгоритм децентрализованной кластеризации, построенный на основе метода *K-means clustering*.

Стоит обратить внимание также на активное развитие в то время методов и моделей децентрализованного машинного обучения, которые базировались на использовании агентов и МАС. Это направление получило название *Agent Mining* [Cao 2010, Cao 2012]. В [Gorodetsky, 2009a, Gorodetsky, 2009b] имеется обзор, который описывает наиболее интересные децентрализованные алгоритмы машинного обучения, разработанные к тому времени.

Работы по созданию р2р-платформы для поддержания взаимодействия и коммуникаций автономных распределенных сущностей (агентов) без централизованных желтых страниц были начаты в 2004 году рабочей группой FIPA² [FIPA, 2004], а уже в 2007 г была опубликована первая программная реализация такой платформы, отвечающая абстрактной архитектуре FIPA [Gorodetsky, 2007]. На ее основе в то время разработано несколько достаточно показательных полностью децентрализованных приложений ИИ [Городецкий, 2008, Городецкий, 2012а и др.].

Что касается четвертого направления исследований в области ДИИ, а именно самоорганизации, то состояние исследований в этой области детально освещено в работах [Городецкий, 2012а,b, Ye, 2016]. В настоящее время эта тема не столь популярна, и в ней имеется еще большой потенциал развития, отдельные аспекты которого описаны далее.

Таким образом, можно утверждать, что к настоящему времени результаты, полученные в области ДИИ, относительно полно покрывают основные его научные направления и являются вполне зрелыми. Однако эти результаты относятся, в основном, к периоду до 2010 гг., и они удовлетворяют требованиям приложений того времени.

4. Актуальные проблемы децентрализованного ИИ

Основные результаты в области ДИИ, несмотря на из достаточную теоретическую зрелость, в настоящее время не могут быть напрямую использованы в приложениях нового поколения, поскольку последние предъявляют к разработкам иные требования, чем те, которые были ха-

² FIPA – Foundation for Intelligent Physical Agents, <http://www.fipa.org/>

рактерны для приложений десятилетней давности. Прежде всего, эти требования касаются масштаба приложений – перспективные приложения намного превосходят по масштабу те, на которые ориентировались разработки периода (1990–2020) гг. Это касается всех четырех проблем, о которых шла речь в разд. 3.

Это, прежде всего, обостряет проблемы вычислительной эффективности. Но заметное увеличение масштаба приводит также к обострению и других проблем. Первой среди них является проблема обеспечения робастности крупномасштабных вычислений, выполняемых в децентрализованной архитектуре. Эта проблема важна и при обычных распределенных вычислениях, при вычислении статистик, при реализации децентрализованных алгоритмов машинного обучения. По-новому масштаб систем влияет на использование суперкомпьютеров. Например, привычные технологии параллельных вычислений, реализуемые в экосистеме Hadoop, непригодны для использования в среде суперкомпьютеров, которые способны реализовать свои возможности только при условии, что все данные находятся в оперативной памяти и не требуется обмен данными с внешней памятью. По этим причинам алгоритмы децентрализованных вычислений в приложениях нового поколения требуют либо модификации, либо полной переработки.

Но децентрализация привносит также свои собственные проблемы, среди которых на первом месте стоит проблема обеспечения безопасности распределенных компонент и каналов передачи данных. Новые проблемы ИТ-приложений касаются, также инфраструктурных и инструментальных средств. Пока в текущих реализациях ИТ-приложений удельный вес ДИИ очень низок. И причины этого кроются, прежде всего, в том, что ДИИ-технологии пока не готовы к применению на индустриальном уровне. Список первоочередных разработок в этой области видится следующим:

1. Разработка новых робастных алгоритмов, зрелых технологий и масштабируемых программных инструментов для реализации концепции парных взаимодействий автономных объектов в сетях с динамической связностью и с интенсивным обменом сообщениями при больших объемах передаваемой информации. Эти средства должны обеспечивать надежные коммуникации при временной потере доступности отдельных адресатов без потери адресуемой информации. Создание платформ индустриального уровня для поддержки р2р-коммуникаций и динамической маршрутизации в сетях большого масштаба и переменной топологии – это одна из важных задач ДИИ в ближайшей перспективе.

2. Развитие известных и создание новых робастных алгоритмов, технологий и программных инструментов поддержки децентрализованных процессов извлечения знаний из данных и машинного обучения, реали-

зуемых, возможно, в реальном времени. В мобильных сетях с ограниченными вычислительными и коммуникационными ресурсами это позволит заметно снизить нагрузку на каналы связи и ускорить процессы обучения. Для решения описанных проблем уже имеется необходимый теоретический базис, созданы экспериментальные программные разработки, однако вычислительно эффективные робастные средства индустриального уровня такого назначения еще предстоит создать.

3. Создание масштабируемых алгоритмов поддержки прикладных р2р-сервисов, а также экосистем таких сервисов, включающих, например, сервисы децентрализованного планирования, р2р-сервисы распределенной координации группового поведения объектов, решающих общую задачу, и другие сервисы прикладного характера.

4. Сложный и важный комплекс проблем децентрализованного ИИ предстоит решить применительно к задачам группового управления. Это новая область исследований и разработок, в которой теоретической основой служат протоколы, т.е. децентрализованные (р2р-) алгоритмы внешнего поведения групп агентов в различных случаях использования. Децентрализованный алгоритм – это протокол взаимодействия распределённых объектов, позволяющий координировать им свое индивидуальное поведение в рамках сценария группового поведения агентов в интересах решения общей задачи. По существу, протоколы консенсуса, протоколы выбора лидера, протокол контрактных сетей, протоколы аукционов, протокол общих намерений, протоколы обмена информацией в интересах поддержания ситуационной осведомлённости участников группового поведения и другие протоколы децентрализованных вычислений, например, децентрализованных алгоритмов обнаружения знаний в данных и машинного обучения – все они могут и должны стать компонентами библиотек стандартных алгоритмов децентрализованных вычислений и группового управления сетями автономных объектов, представленных в программной среде своими агентами.

5. Алгоритмы и технологии самоорганизации, которые работают в более широком контексте, вплоть до глобального. Децентрализованные алгоритмы ИИ составляют основу самоорганизации. Однако современная концепция самоорганизующихся алгоритмов предполагает использование только локальной информации, т.е. информации, которую агент может получить от своих соседей для локальной оптимизации своего поведения. Однако имеется ряд теоретических предложений, а также конкретных разработок, которые позволяют строить самоорганизующиеся системы децентрализованной архитектуры с привлечением более широкого и даже глобального контекста. Примером являются системы самоорганизации с использованием цифровых полей [Samurçi, 2007], а также модели самоорганизации на основе аморфных вычислений [Abelson, 2000].

Эти и другие подходы для формирования глобального контекста на основе локальной информации объединяются понятием активных (баз) данных и знаний. По определению, база данных и знаний называется активной, если в ней возможно выполнение не только тех действий, которые явно указывает пользователь. В них могут выполняться и другие действия проактивного характера в соответствии с правилами (знаниями), заложенными в модель данных. Обычно активность модели данных и знаний используется для контроля и поддержания её непротиворечивости и целостности. В некоторых случаях в модель активных знаний включают вычисление каких-то атрибутов. Если значения этих атрибутов оказываются в определенном заранее диапазоне, то этот факт инициирует проактивное поведение системы. Типичным примером такой проактивности в распределённой системе является таймаут, контролирующий корректность процессов в системе во времени и формирующий управляющие воздействия при нарушении таймаутов.

Концепция активных знаний оказывается очень продуктивной для самоорганизующихся систем. Расширение локально доступного контекста объектов сети в интересах процесса принятия решений с помощью активных знаний является одним из вариантов повышения автономности и ситуационной осведомленности распределённых систем ДИИ. Продемонстрируем возможности активных знаний расширять локальный контекст принятия решений на примере.

Пример. Динамическая маршрутизация в сети с переменной топологией. Рассмотрим концепцию аморфных вычислений [Abelson, 2000]. В её основе лежит модель самоорганизации, заимствованная из морфогенеза. В ней рассматривается векторная модель морфогена, в которой каждое его измерение может использоваться для управления тем или иным процессом, свойством и т.п. Модель аморфных вычислений рассматривает большое число одинаково запрограммированных простых устройств, которые распределены на поверхности или в некотором объёме случайным образом. Каждое устройство может воспринимать внешнюю среду и воздействовать на неё. Полагается, что устройства обладают очень ограниченными ресурсами и воспринимают ограниченный объём локальной информации, а также могут выходить из строя. Полагается также, что каждое устройство имеет внутреннее состояние, зависящее от его предыдущих действий, имеет свою нить исполнения и способно генерировать случайные числа. Устройства могут обмениваться сообщениями через канал связи с малой дистанцией достижимости. Устройства сети вначале ничего не знают о её топологии, в ней нет централизованного источника информации, глобального времени и маяков для привязки к координатам. Ком-

муникационная среда поддерживает распространение цифрового поля каждого устройства, задаваемого пространственно-зависимой структурой данных [Samurǵı, 2007].

Оказывается, что такая достаточно простая модель вычислений может использоваться для построения весьма эффективных механизмов самоорганизации за счёт распространения части глобального контекста по сети. Например, некоторое устройство-источник может посылать соседям своё имя и “морфоген” – число, равное нулю. Получив такое сообщение, каждый сосед пересылает его своим соседям, добавляя к значению морфогена с именем его источника единицу. Этот процесс продолжается до тех пор, пока не будут достигнуты все узлы коммуникационной сети.

Каждое устройство может запомнить минимальное значение этого морфогена. При необходимости устройство может использовать его как значение кратчайшего пути до узла-источника, если длина пути измеряется количеством рёбер на нем. Далее каждый узел может определить “локальную ориентацию” узла, т.е. направление на источник или от него, запрашивая значение морфогена этого узла у соседей. Направление на источник определяется тем узлом (узлами), в котором значение морфогена источника имеет минимальное значение. Аналогично направление от источника соответствует направлению на узлы со значением морфогена на единицу больше, чем собственное его значение.

Если в качестве источников цифрового поля используются агенты сети, то информацию о «локальной ориентации» узла сети на источник агент любого узла сети может получить путём опроса соседних узлов. Если источник является адресатом сообщения, которое должен послать некоторый узел, то в результате этого опроса он может динамически определять первый участок маршрута передачи сообщения своему адресату. Далее так могут поступать и последующие узлы на пути от источника к адресату. В итоге искомый маршрут передачи сообщения будет сформирован автоматически в децентрализованном стиле с помощью модели аморфных вычислений.

Этот пример показывает важную роль активных знаний в решении задачи адресации сообщений в системах с мобильными объектами и ограниченной дальностью коммуникаций. Заметим, что в этом случае локальный контекст узла сети расширяется за счёт цифрового поля, доставляющего распределённую информацию о связности сети.

Таким образом, использование активных знаний в распределённых системах с самоорганизацией позволяет получать более эффективные самоорганизующиеся системы за счёт «доставки» информации о глобальном контексте в локальные узлы принятия решений.

Заключение

Крупный масштаб, высокий уровень сложности и распределенный характер ИТ-приложений нового поколения и задач, которые они должны решать, как правило, в реальном времени и в условиях неопределенности – это современная реальность. Сложные ИТ-приложения нового поколения представляют собой сети мобильных объектов, функционирующие в беспроводной коммуникационной среде. Эти объекты за счет объединения своих ресурсов и интенсивного взаимодействия оказываются в состоянии решать самые сложные задачи даже при ограниченных вычислительных ресурсах. Для современного ИИ такая ситуация является новой, и она предъявляет новые требования, с которыми невозможно справиться без пересмотра ранее принятых парадигм управления и подходов, без ужесточения различных показателей качества работы системы. Анализ современных трендов в области передовых концепций и разрабатываемых проектов показывает возрастающую роль ИИ, причем в первую очередь, ДИИ.

В работе проведен анализ передовых концепций построения ИТ-приложений нового поколения и конкретных разработок, дан краткий анализ современных достижений в области ДИИ и самоорганизации, которые теоретически в состоянии поддержать практическую реализацию таких приложений. Однако эти разработки пока не готовы к использованию на индустриальном уровне с учетом новых реалий и требований к ним со стороны современных приложений. Базовые ориентиры развития ИИ в рассматриваемом контексте можно охарактеризовать такими ключевыми направлениями развития, как:

- децентрализованные вычисления в динамических сетях на основе алгоритмов парных взаимодействий;
- динамические р2р-коммуникационные сети и среды,
- моделирование группового поведения и групповое управление на основе протоколов;
- библиотеки прикладных протоколов взаимодействия агентов в разных задачах и случаях использования и их экосистемы;
- крупномасштабные робастные вычислительно эффективные алгоритмы децентрализованных вычислений в р2р-сетях.
- новые децентрализованные алгоритмы, технологии и программные инструменты для поддержки процессов извлечения знаний из данных и машинного обучения;
- масштабируемые алгоритмы и технологий поддержки прикладных р2р-сервисов, а также экосистем таких сервисов,
- самоорганизация в глобальном контексте.

Список литературы

- [Гидаспов, 2022] Гидаспов И., Акопян А. Что такое DeFi: Все о децентрализованных финансах. – URL <https://currency.com/ru/chto-takoe-defi>.
- [Городецкий, 2012а] Городецкий В.И. Самоорганизация и многоагентные системы // Модели многоагентной самоорганизации. Известия РАН «Теория и системы управления». – 2012. – № 2.
- [Городецкий, 2012б] Городецкий В.И. Самоорганизация и многоагентные системы. II. Приложения и технология разработки // Известия РАН. Теория и системы управления. – 2012. – № 3.
- [Городецкий, 2008] Городецкий В.И., Карсаев О.В., и др. Инструментальные средства для открытых сетей агентов // Изв. РАН. ТИСУ. – 2008. – № 3.
- [Карелина, 2021] Карелина А. Что такое Web3. Объясняем простыми словами. – <https://secretmag.ru/enciklopediya/chto-takoe-web3-obyasnyаем-prostymi-slovami.htm>.
- [Cao, 2022] Cao L. Decentralized AI: Edge Intelligence and Smart Blockchain, Metaverse, Web3, and DeSci. IEEE Intelligent Systems, June 2022.
- [Abelson, 2000] Abelson H., Allen D., et al. Amorphous Computing // Communication of the ACM. – 2000. – Vol. 43, No. 5.
- [Camurri, 2007] Camurri M., Mamei M., Zambonelli F. Urban Traffic Control with Co_Fields // Series Lecture Notes in Artificial Intelligence. V. 4389/ Eds D. Weyns, H.V.D. Parunak, F. Michel. Springer, 2007.
- [Cao, 2010] Agent Mining Special Interest Group. – <http://www.agentmining.org>.
- [Cao, 2012] Cao L., Weiss G., and Yu Ph.S. A brief introduction to agent mining // Autonomous Agents and Multi-Agent Systems. – 2012. – Vol. 25.
- [Cao, 2022] Cao L. Decentralized AI: Edge Intelligence and Smart Blockchain, Metaverse, Web3, and DeSci. IEEE Intelligent Systems, June 2022.
- [Chan, 1999] Chan Ph. K., Fan W., Stolfo S.J. Distributed Data Mining in Credit Card Fraud Detection. IEEE Intelligent Systems, 1999, Vol. 14.
- [Cohen, 1991] Cohen P and Levesque H.J. Teamwork // Nous. – 1991. – No. 25.
- [Datta, 2006] Datta K., Bhaduri C. Giannella R. Wolff R. and Kargupta H. Distributed data mining in peer-to-peer networks // IEEE Internet Computing special issue on Distributed Data Mining. – 2006. – 10 (4).
- [Di Marzo Serugendo, 2005] Di Marzo Serugendo G., Gleizes M. P., Karageorgos A. Self Organisation in Multi Agent Systems// Rapport de recherche IRIT/2005_18_R, IRIT. Universite Paul Sabatier, Toulouse. – http://www.irit.fr/TFGSO/DOCS/TFG2/TFGIISO_LongReport.pdf.
- [Ferber, 2014] Ferber J. Foreword. In Cossentino M., Hilaire V., Molesini A., Seidita V. (Eds.). Handbook on Agent-Oriented Design Processes. – Springer. 2014.
- [FIPA, 2004] FIPA P2P NA WG6. Functional Architecture Specification Draft 0.12. – <http://www.fipa.org/subgroups/P2PNA-WG-docs/P2PNA-Spec-Draft0.12.doc>.
- [Gorodetsky, 2007] Gorodetsky V., Karsaev O., et al. P2P Agent Platform: Implementation and Testing. In S.R.H. Joseph, Z. Despotovic, G. Moro, S. Bergamaschi (Eds): Agents and Peer-to-Peer Computing, 6th International Workshop, AP2PC 2007, Honolulu, Hawaii, USA, May 14-18, 2007, Revised and Selected Papers. Lecture Notes in Computer Science. Vol. 5319. – Springer 2010.

- [Gorodetsky, 2009a]** Gorodetsky V., Moemeng Ch., Cao L. Agent-Based Distributed Data Mining: A Survey. In: Data Mining and Multi-agent Integration. L. Cao (Ed.). – Springer 2009.
- [Gorodetsky, 2009b]** Gorodetsky V., Cao L., Mitkas P.A.. Agent Mining: The Synergy of Agents and Data Mining // IEEE Intelligent Systems, May, 2009. – Vol. 24, No. 3.
- [Gorodetsky, 2020]** Gorodetsky V. Multi-agent Autonomous Group Control in Collective Robotics-Based Assembly. In CEUR-WS.org vol. 1, 2648/paper.pdf “Russian Advances in Artificial Intelligence: selected contributions to the Russian Conference on Artificial intelligence (RCAI 2020), October 10-16, 2020, Moscow, Russia.
- [Grosz, 1995]** Grosz B. and Kraus S. Collaborative Plans for Complex Group Actions // Artificial Intelligence. – 1996. – Vol. 86, No. 2.
- [Jennings, 1995]** Jennings N.R. Controlling Cooperative Problem Solving in Industrial Multi-Agent Systems Using Joint Intentions // Artificial Intelligence. – 1995. – Vol. 75, No. 5.
- [Geihs, 2020]** Geihs K. Engineering Challenges Ahead for Robot Teamwork in Dynamic Environments // Applied Sciences. – 2020. – Vol. 10, Issue 4, 1368. – <https://doi.org/10.3390/app10041368>.
- [Kaminka, 2005]** Kaminka G.A., Frenkel I. Flexible Teamwork in Behavior-Based Robots. In: AAI. Ed. by M. Veloso, S. Kambhampati. AAI Press, MIT Press, 2005.
- [Lee, 2021]** Lee L., Braud T., Zhou P., et al, All one needs to know about metaverse: A complete survey on technological singularity, virtual ecosystem, and research agenda, 2021, arXiv:2110.05352.
- [May, 2010]** May M, Saitta L. Ubiquitous Knowledge Discovery. Challenges, Techniques, Applications // Lecture Notes in Computer Science. Vol 6202. – Springer, 2010.
- [Nasir, 2021]** Nasir M., Bhutta M., Khwaja A.K. et al. Survey on Blockchain Technology: Evolution, Architecture and Security // IEEE Access. – 2021. – Vol. 10.
- [Prodromidis, 2000]** Prodromidis A.L., Chan Ph.K., Stolfo S.J.. Meta-Learning in Distributed Data Mining Systems: Issues and Approaches // In: Advances of Distributed Data Mining, AAI Press, 2000.
- [Sycara, 2003]** Sycara K., Paolucci M., Giampapa J., et al. The RETSINA Multi-agent Infrastructure // Autonomous Agents and Multi-agent Systems. – 2003. – Vol. 7, No. 1.
- [Tambe, 1999]** Tambe M., Shen W-M., Mataric M., et al. Teamwork in Cyberspace: Using TEAMCORE to Make Agents Team-Ready // Proceedings of AAI Spring Symposium on Agents in Cyberspace, 1999.
- [Tambe, 1997]** Tambe M. Towards Flexible Teamwork // Journal of Artificial Intelligence Research. – 1997. – No. 74.
- [Wolff, 2004]** Wolff R., and Schuster A. Mining association rules in peer-to-peer systems. IEEE Transactions on Systems, Man and Cybernetics. – December 2004. – Part B, 34 (6). – P. 2426-2438.
- [Ye, 2016]** Ye D., Zhang M., and Vasilakos A.V.A Survey of Self-organisation Mechanisms in Multi-Agent Systems // IEEE Transactions on Systems, Man and Cybernetics. – 2014. – 47 (3).
- [Zhang, 2022]** Zhang Y. Mobile Edge Computing // Simula SpringerBriefs on Computing. – 2022. – Vol. 6.

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА НАЗНАЧЕНИЯ ПЕРСОНАЛИЗИРОВАННОГО ЛЕЧЕНИЯ ПО АНАЛОГИИ*

В.В. Грибова (*gribova@iacp.dvo.ru*)

Р.И. Ковалев (*koval-995@mail.ru*)

Институт автоматики и процессов управления ДВО РАН,
Дальневосточный федеральный университет, Владивосток

Д.Б. Окунь (*okdm@iacp.dvo.ru*)

Институт автоматики и процессов управления ДВО РАН,
Владивосток

В работе описывается система назначения лечения на основе прецедентов. Сформированы требования и принципы работы системы. Уникальной особенной является извлечение прецедентов на основе гибридного подхода.

Ключевые слова: СППВР, прецеденты, интеллектуальная система.

Введение

Создание систем поддержки принятия решений для практикующих врачей – важная и актуальная задача, основная цель которой – снижение числа врачебных ошибок, которые, по оценкам специалистов, достигают 30%. И это, несмотря на значительный и качественный скачок в медицинской диагностике и лечении заболеваний [Лудупова, 2016].

В настоящее время создано много систем поддержки принятия врачебных решений (СППВР), как правило, основанных на знаниях и машинном обучении [Рыбина, 2014]. Однако, в некоторых клинических случаях знаний и данных бывает недостаточно (например, в начале пандемии COVID-19 отмечался, как дефицит медицинских знаний, так и доступных для обработки наборов клинических данных – историй болезни). Именно в таких условиях системы на основе прецедентного подхода проявляют

* Работа выполнена при частичной финансовой поддержке РФФИ (19-2901077), а также ДВФУ (программа Приоритет-2030).

себя наилучшим образом. На рынке существуют подобные системы, однако, они ориентированы на частную проблему (диагностику или лечение одного, в лучшем случае нескольких заболеваний).

Целью работы является разработка методов, алгоритмов, а так же программная реализация системы поддержки принятия решений по назначению лечения на основе прецедентов, применимой во всех разделах медицины.

1. Обзор текущего состояния систем на основе прецедентного подхода

Системы на основе прецедентного подхода позволяют решить новую, неизвестную задачу, используя или адаптируя решение уже известной задачи, т.е., используя уже накопленный опыт решения подобных задач. К настоящему времени разработано множество различных систем, реализующих прецедентный подход и успешно применяемых в разных областях (медицина, экономика, юриспруденция, технические системы и т.д.). Одними из первых медицинских систем являются MEDIATOR – используется в психологии [Simpson, 1985], CASEY – в медицинской диагностике [Koton, 1989], Protos – диагностика нарушения слуха [Bareiss et al, 1987], CARE-PARTNER – лечение пациентов после пересадки стволовых клеток [Bichindaritz et al, 1998] и др.

Среди современных разработок можно выделить CBR-DENT, которая используется в стоматологии для поиска похожих случаев при лечении и диагностике. Система основана на одном из самых популярных методов k-ближайших соседей и использует метрику евклидово-лагранжевого расстояния [Dongxiao et al, 2010]. ак же на основе этого метода разработана система ExcelicareCBR [Branden et al, 2011] для лечения рака, а в работе [Marling et al, 2008] описывается создание системы по терапии диабета.

Основными преимуществами систем на основе метода k-ближайших соседей являются простота реализации и универсальность в смысле независимости от специфики конкретной проблемной области. Суть метода состоит в следующем, для определения степени сходства на множестве параметров вводится некоторая метрика. Далее в соответствии с выбранной метрикой определяются координаты текущей ситуации и прецедентов из БП (база прецедентов). Затем рассчитываются расстояния между этими точками и выбираются наиболее близкие в соответствии с порогом схождения.

К недостаткам систем на основе метода ближайшего соседа можно отнести сложность выбора метрики для определения степени сходства и прямую зависимость требуемых вычислительных ресурсов от размера БП, а также неэффективность при работе с неполными данными [Варшавский и др., 2009].

Метод извлечения прецедентов на основе деревьев решений использует система ReCall от ISoft [Hadj-Mabrouk, 2020]. В ней используется объектно-ориентированный графический язык для представления сложных структур прецедентов. Система применима в таких областях как, устранение неисправностей, комплексная диагностика, интеллектуальный анализ данных. Однако, без помощи программистов эксперты предметной области не могут самостоятельно сопровождать систему ввиду использования сложной модели представления данных, неясной и неочевидной для них.

Данный метод особенно эффективен на больших БП, т.к. основная часть работы по извлечению прецедентов выполняется заранее на этапе построения дерева решений, что значительно сокращает время поиска решения. Метод предполагает нахождение требуемых прецедентов путем разрешения вершин дерева решений. Каждая вершина дерева указывает, по какой ее ветви следует осуществлять дальнейший поиск решения.

Существенным недостатком систем на основе деревьев решений является то, что деревья решений дают полезные результаты только в случае независимых признаков [Варшавский и др., 2008]. В противном случае они лишь создают иллюзию логического вывода.

Проанализировав существующие системы рассуждения по аналогии, был сделан вывод, что на текущий момент не существует программных решений, ориентированных на широкий класс задач, или же системы обособлены и возможность их использования как составной части гибридных интеллектуальных систем отсутствует. Одной из главных проблем прецедентного подхода является выбор соответствующей метрики для индексации и сравнения прецедентов. Так же серьезным вопросом является интерпретация дискретных и качественных значений.

Дальнейшее развитие прецедентного подхода связано с разработкой новых способов представления знаний в виде прецедентов, предложением новых механизмов (методов) реализации отдельных этапов, а также использование гибридных подходов, сочетающих сразу несколько способов.

1.1. Постановка задачи

Данная работа ориентирована на поиск прецедентов при назначении лечения независимо от раздела медицины и конкретного заболевания. Актуальность данного направления обусловлена тем, что оно позволяет работать с малыми объемами данных, в то время как другие подходы в этом случае могут приводить к неточным и даже ошибочным выводам [Salamun et al, 2021].

Разрабатываемая система должна интегрироваться в систему поддержки принятия решений по назначению лечения на основе знаний [Грибова и др., 2020], а система по прецедентам рассматривается как вспомогатель-

ная в случае, когда система на знаниях не смогла предложить решение. В этом случае проблема постоянно увеличивающейся БП и, как следствие, возрастающей вычислительной сложности, не является значимой.

Чтобы обеспечить универсальность применения системы, необходимо определить общие принципы определения схожести признаков, характерные для всех разделов медицины. Не менее важным свойством такой системы должны быть ее понятность для врачей – пользователей системы.

Для реализации всех поставленных задач нами предлагается:

1. Гибридный подход к извлечению прецедентов. Степени сходимости признаков будут определяться на основе терминологической базы с помощью метода *k*-ближайших соседей. Терминологическая база является ключевым элементом разрабатываемой системы. Она содержит описание всевозможных признаков и наблюдений, использующиеся для формирования истории болезни. Также определены типы их шкал и возможные значения;

2. Данные в системе должны формироваться и модифицироваться в процессе эксплуатации системы, поэтому необходимо обеспечить возможность их изменения без привлечения разработчиков. Эффективным решением является использование онтологического подхода, который, как отмечено в [Gavrilova et al, 2020], стал де-факто стандартом при разработке интеллектуальных систем. При наличии соответствующих редакторов (управляемых онтологией) он обеспечит понятность формирования данных, возможность реализации унифицированного онтолого-ориентированного решателя, а также формирование детализированного объяснения.

3. Результатом работы должна быть не только демонстрация ранжированных по степени сходства историй болезни, но и детализированное объяснение, почему те или иные истории болезни оказываются сходными.

2. Архитектура специализированной интеллектуальной системы для назначения медикаментозного лечения по аналогии

В состав интеллектуальной системы для назначения медикаментозного лечения входят информационные и программные компоненты. К информационным компонентам относятся онтологии и порожденные на их основе базы данных. К программным компонентам относятся средства редактирования данных, а также решатель задач.

2.1. Информационные компоненты разрабатываемой оболочки

Для достижения поставленной цели было разработано множество информационных компонентов [Грибова и др., 2018a, Gribova et al, 2018b] таких, как онтология фармакологического справочника, онтология базы медицин-

ской терминологии и наблюдений, онтология персональной медицинской электронной карты пациента. Данные онтологии позволяют четко задать структуру описания данных, в форме доступной пользователю, а также определить семантические зависимости. На их основе созданы информационные ресурсы, позволяющие формировать и описывать медицинские данные независимо от клинического раздела медицины, и открывающие возможность в реализации систем, решающих широкий класс задач.

Отличительной чертой разрабатываемой системы является База медицинских признаков и терминов, порожденная по данной онтологии, которая описывает необходимую медицинскую терминологию, а также содержит знания о признаках и наблюдениях, используемых в медицине (рис. 1).

Все понятия можно разделить на два типа «Признаки» и «Факторы». Признак описывает проявление какого-либо клинического симптома или проявления, такие как жалобы пациента, результаты анализов и т.д. Фактор же отображает какое-либо событие или случай в жизни пациента, например курение, беременность. Все признаки или факторы подразделяются на простые, такие как «Пол», «Возраст», и составные, имеющие некоторый набор характеристик, например, «Боль в суставе» обладает такими характеристиками, как локализация, интенсивность, периодичность, характер. Возможные значения признаков (факторов) или же их характеристик разделяются на числовые и качественные.

Качественные могут принимать интегрирующие значения. Это позволяет задать похожесть и сгруппировать несколько однородных значений, например, интегрирующее значение «сильная» - сильная, резкая, резчайшая; характеристика «Локализация» признака «Боль в суставе» имеет интегрирующее значение «от движения», включающая значения бег, ходьба, кашель, изменение положения.

Все качественные значения, в том числе интегрирующие, имеют порядковую шкалу или же шкалу наименований [Цветов, 2018]. Шкала наименований просто содержит набор возможных значений признаков, которые максимально различны друг от друга.

Порядковая шкала предполагает ранжирование (упорядочивание) значений признака в зависимости от масштабирования, например, значения характеристики «интенсивность» признака «Головная боль» имеют следующие значения в порядковой шкале: очень слабая, слабая, умеренная, сильная, резкая, резчайшая.

Числовые значения признаков (факторов) или характеристик содержат описания их референсных диапазонов, которые могут зависеть от различных параметров, таких как пол, возраст; особые состояния организма (например, беременность); эпидемиологические факторы (контакт с больным, контакт с животным, характер работы), аллергические факторы и факторы риска (вредные привычки, профессиональные вредности, сезонность).

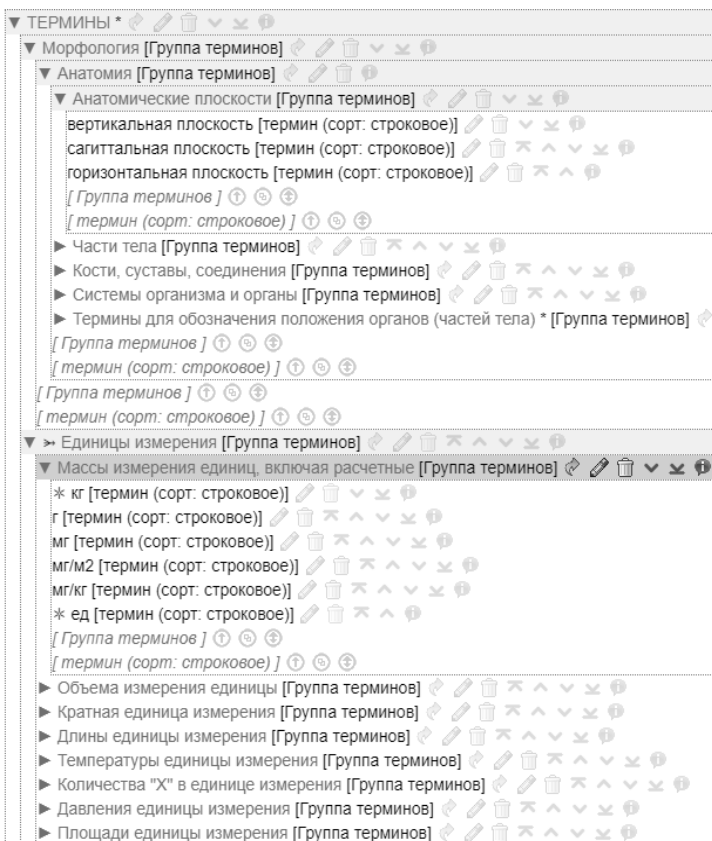


Рис. 1. База медицинских терминов и признаков

2.2. Программные компоненты разрабатываемой системы

Программные компоненты системы включают в себя решатель задач и средства редактирования данных.

Решатель задач разбит на два компонента, одна его часть реализована на облачной платформе IASaaS [Gribova et al, 2018c], здесь выполняется интерфейсная подсистема и первичная подготовка данных (рис. 2), вторая часть реализована как внешний агент, где происходит непосредственный расчет сходимости.

- Острый холецистит тест1(История болезни)
 - Острый холецистит (предварительный диагноз)
 - Клинический диагноз врача
 - Исследования лабораторные
 - Биохимическое исследование крови (Группа признаков (вид исследования))
 - 1 (Номер записи)
 - 07.11.2015-22:10:42.000 (дата)
 - Белок общий в сыворотке (Признак)
 - г/л (ед.изм.)
 - 77.1 (значение)
 - Креатинин крови (Признак)
 - мкмоль/л (ед.изм.)
 - 79 (значение)
 - Мочевина в крови (Признак)
 - Билирубин общий (Признак)
 - Билирубин прямой (Признак)
 - Билирубин не прямой (Признак)
 - Глюкоза крови (Признак)
 - Калий в крови (Признак)
 - Натрий в крови (Признак)
 - Аспартатаминотрансфераза крови (Признак)
 - Аланинаминотрансфераза крови (Признак)
 - Альфа-амилаза крови (Признак)
 - Фосфатаза щелочная (Признак)
 - Липаза в крови (Признак)
 - Амилаза панкреатическая (Признак)
 - Клинический анализ крови (Группа признаков (вид исследования))
 - Биохимическое исследование мочи (Группа признаков (вид исследования))
 - Жалобы при обращении
 - Боль в животе (Признак)
 - Присутствие (Характеристика)
 - имеется (значение)
 - Характер (Характеристика)
 - Локализация (Характеристика)
 - правое подреберье (значение)
 - Иррадиация (Характеристика)

Рис. 2. Исходный случай

Решатель представляет собой онтолого-ориентированный алгоритм (ontological reasoner), который для поиска похожих клинических случаев производит обход базы прецедентов и попарно сопоставляет информацию из персональной медицинской карты пациента (ПЭМК), а также приводит все наблюдения (признаки) к единой метрике.

Расчет сходимости выполняется совокупно по каждому признаку, для чего каждому наблюдению в ПЭМК и прецеденте вместо значения присваивается некоторый числовой эквивалент от 0 до 10 в соответствии с базой терминологии и наблюдений.

Если качественный признак имеет порядковую шкалу, то ему сопоставляется соответствующее число. Если же используется шкала наименований, то в случае совпадения значений или же, попаданию в одно и тоже

интегрирующее значение, признакам в ПЭМК и прецеденте присваивается 0, т.е. полное совпадение; в случае если значения признаков различны, то одному присваивается 0, а другому 10, т.е., максимальное различие.

При рассмотрении числовых значений 0 сопоставляется признаку из ПЭМК, а эквивалент признака из прецедента высчитывается от значения из ПЭМК с шагом диапазона нормы этого признака, но не более 10.

Так же алгоритм работы решателя подразумевает обработку пропущенных признаков. В случае если признак отсутствует в прецеденте, то по этому признаку считается максимальное различие, если же в ПЭМК – определяется частичная сходимость.

- Острый холецистит ЭТАЛ(История болезни) **"100.0%"**
- Острый холецистит ЭТАЛОН(История болезни) **"100.0%"**
- Острый Холецистит 35193/15(История болезни) **"54.67241362068964%"**
- Хронический холецистит(История болезни) **"61.719509146341146%"**
 - Хронический холецистит (обострение) (предварительный диагноз)
 - Клинический диагноз врача
 - Исследования инструментальные
 - Исследования лабораторные
 - Биохимическое исследование крови (Группа признаков (вид исследования))
 - 1 (Номер записи)
 - 06.05.2016-16:14:00.000 (дата)
 - Белок общий в сыворотке (Признак)
 - г/л (ед.изм.)
 - 75 (значение)
 - Креатинин крови (Признак)
 - мкмоль/л (ед.изм.)
 - 139 (значение)
 - Билирубин общий (Признак)
 - Глюкоза крови (Признак)
 - Аспартатаминотрансфераза крови (Признак)
 - Аланинаминотрансфераза крови (Признак)
 - Альфа-амилаза крови (Признак)
 - Мочевина в крови (Признак)
 - Билирубин не прямой (Признак)
 - Билирубин прямой (Признак)
 - Фосфатаза щелочная (Признак)
 - Клинический анализ крови (Группа признаков (вид исследования))
 - Общий анализ мочи (Группа признаков (вид исследования))
 - Жалобы при обращении
 - Боль в животе (Признак)
 - Присутствие (Характеристика)
 - имеется (значение)
 - Локализация (Характеристика)
 - верхний отдел живота (значение)
 - Интенсивность (Характеристика)
 - Периодичность (Характеристика)

Рис. 3. Наиболее похожие прецеденты из БП, объяснение результата

Такой подход позволяет определить сходимость значений признаков на основе его обобщенного, а не абсолютного значения, с учетом различных факторов (пола, возраста, наличия беременности и др.).

Непосредственный расчет схожести случая из ПЭМК и прецедента происходит через Евклидово расстояние, а затем переводится в проценты. Первые пять прецедентов набравшие свыше 60% возвращаются в подсистему на платформе IASPaas и предлагаются пользователю в качестве результатов работы (см. рис. 3). После чего пользователь может провести уточненный поиск прецедента, выбрав интересующие его признаки.

Заключение

В работе дан обзор современному состоянию в области разработки систем, помогающих врачу назначить медикаментозное лечение с учетом его персональных данных (анамнеза жизни, сопутствующих заболеваний, возраста, предъявляемых жалоб и др.).

Особенностями разработанной системы, принципиально отличающими ее от других медицинских систем, является:

- ориентация на широкий спектр заболеваний;
- формирование информационных ресурсов с использованием редакторов знаний/данных, управляемых соответствующими онтологиями, что соответствует современному подходу к разработке интеллектуальных систем;
- использование онтологического подхода и редактора, имеющего несколько вариантов пользовательского интерфейса, управляемого онтологией, позволяет включить в процесс разработки медицинской интеллектуальной системы экспертов предметной области;
- результатом работы системы является не только набор похожих историй болезни, но и детализированное объяснение предложенного результата;
- система реализована как облачный сервис. Это позволяет увеличить аудиторию пользователей.

Список литературы

- [Лудупова, 2016] Лудупова Е.Ю. Врачебные ошибки. Литературный обзор //Вестник Росздравнадзора. – 2016. – №. 2. – С. 6-15.
- [Рыбина, 2014] Рыбина Г.В. Основы построения интеллектуальных систем. – 2014.
- [Simpson, 1985] Simpson R.L. A Computer Model of Case-Based Reasoning in Problem Solving: An Investigation in the Domain of Dispute Mediation // Technical Report GIT-ICS85/18, Georgia Institute of Technology, School of Information and Computer Science, Atlanta, US, 1985.
- [Koton, 1989] Koton P. Using experience in learning and problem solving. Massachusetts Institute of Technology, Laboratory of Computer Science, Ph.D. Thesis MIT/LCS/TR-441, 1989.
- [Bareiss et al, 1987] Bareiss E.R., Porter B.W., and Wier C.C. Protos: An exemplar-based learning apprentice // in Proceedings of the fourth international workshop on machine learning. August 1987. – P. 12-23.

- [Bichindaritz et al, 1998] Bichindaritz I., Kansu E., Sullivan K.M. Case-based reasoning in care-partner: Gathering evidence for evidence-based medical practice // European workshop on advances in case-based reasoning. – Springer, Berlin, Heidelberg, 1998. – P. 334-345.
- [Dongxiao et al, 2010] Gu, Dongxiao & Liang, Chang-yong & Li, Xing-Guo & Yang, Shan-Lin & Zhang, Pei. Intelligent Technique for Knowledge Reuse of Dental Medical Records Based on Case-Based Reasoning // Journal of medical systems. – 2010. – 34. – P. 213-22. – 10.1007/s10916-008-9232-y.
- [Branden et al, 2011] Branden, Martijn & Wiratunga, Nirmalie & Burton, Dean & Craw, Susan // Integrating case-based reasoning with an electronic patient record system. Artificial intelligence in medicine. – 2011. – 51. – P. 117-23. – 10.1016/j.artmed.2010.12.004.
- [Marling et al, 2008] Marling C., Shubrook J., and Schwartz F. Case-based decision support for patients with type 1 diabetes on insulin pump therapy // Advances in Case-Based Reasoning, Lecture Notes in Computer Science. – 2008. – Vol. 5239. – P. 325-339.
- [Варшавский и др., 2009] Варшавский П.П., Еремеев А.П. Моделирование рассуждений на основе прецедентов в интеллектуальных системах поддержки принятия решений // Искусственный интеллект и принятие решений. – 2009. – № 2. – С. 45-57.
- [Hadj-Mabrouk, 2020] Hadj-Mabrouk H. Application of Case-Based Reasoning to the safety assessment of critical software used in rail transport // Safety science. – 2020. – Vol. 131. – P. 104928.
- [Варшавский, 2008] Варшавский П.П. Механизмы правдоподобных рассуждений на основе прецедентов (накопленного опыта) для систем экспертной диагностики // Труды 11-ой национальной конференции по ИИ с международным участием (КИИ-2008). Т. 2. – М.: ЛЕНАНД, 2008. – С. 321-329.
- [Salamun et al, 2021] CBR C.B.R., Alghoritm K.N.N. A Testing of Case-Base Reasoning for Covid-19 Patient Status Confirmation // Indonesian Journal of Artificial Intelligence and Data Mining (IJAIMD). – 2021. – Vol. 4, No. 2. – P. 72-78.
- [Грибова и др., 2020] Грибова В.В., Ковалев Р.И., Окунь Д.Б. Специализированная оболочка для построения интеллектуальных систем назначения медикаментозного лечения // Искусственный интеллект и принятие решений. – 2020. – № 4. – С. 66-79. – Doi: 10.14357/20718594200407.
- [Гаврилова и др., 2020] Гаврилова Т.А., Страхович Э.В. Визуально-аналитическое мышление и интеллект-карты в онтологическом инжиниринге // Онтология проектирования. – 2020. – Т. 10, №. 1 (35). – С. 87-99.
- [Грибова и др., 2018а] Грибова В.В., Окунь Д.Б. Онтологии для формирования баз знаний и реализации лечебных мероприятий в медицинских интеллектуальных системах // Информатика и системы управления. – 2018. – № 3. – С. 71-80.
- [Gribova et al, 2018b] Gribova V.V. et al. Software Toolkit for Creating Intelligent Systems in Practical and Educational Medicine // 2018 3rd Russian-Pacific Conference on Computer Technology and Applications (RPC-2018). – IEEE. 2018. – С. 1-5.
- [Цветов, 2018] Цветов В.П. О вложении измерительных шкал. – 2018.
- [Gribova et al, 2018c] Грибова В.В., Клещев А.С., Москаленко Ф.М., Тимченко В.А., Федорищев Л.А., Шалфеева Е.А. Облачная платформа IASaaS для разработки оболочек интеллектуальных сервисов: состояние и перспективы развития // Программные продукты и системы. – 2018. – № 3.

КОРРЕКЦИЯ ОШИБОК ПРИ ОБУЧЕНИИ В ЗАДАЧЕ УПРАВЛЕНИЯ ИНТЕЛЛЕКТУАЛЬНЫМ РОБОТОМ

Д.А. Добрынин (*rabota51@mail.ru*)
Федеральный исследовательский центр
«Информатика и управление» РАН, Москва

В работе описывается подход к улучшению качества обучения системы управления интеллектуальным роботом, основанный на коррекции ошибок. В качестве модельной задачи выбрано обучение мобильного робота движению по контрастной полосе. Показано, что качество обучения может быть улучшено путем удаления плохих гипотез и последующего дообучения. Эксперименты на симуляторе роботов показали улучшение результатов обучения при использовании коррекции ошибок.

Ключевые слова: машинное обучение, робот, обучение с подкреплением.

Введение

В настоящее время активно ведутся разработки в области интеллектуальных роботов, что связано с большими перспективами применения таких систем. Одним из важных свойств интеллектуального робота является способность адаптироваться к меняющимся условиям среды, в которой функционирует робот. Система управления робота должна сама настраиваться на эти изменения, что предполагает наличия у нее свойств обучения.

Обучение интеллектуального робота можно организовывать по-разному. Наиболее простой способ организации обучения – это обучение с «учителем», которое подразумевает обучение на заранее классифицированных примерах. Такой способ обучения имеет серьезные ограничения в тех случаях, когда заранее неизвестно – каким действиям необходимо учить робота. Более предпочтительным является способность робота обучаться самостоятельно. При этом роботу ставится цель, которую необходимо достигнуть, а последовательность действий робот должен выработать сам. Учителем в данном случае выступает сама среда, в которой функционирует робот, а цель поведения робота задается с помощью функций наказания и поощрения. “Reinforcement learning” – обучение с подкреплением относится к таким методам.

В настоящее время обучение с подкреплением активно развивается для нейронных сетей [Sutton, 2018], особенно для глубоких нейронных сетей [Moerland, 2020]. Особенности такого обучения являются низкая скорость обучения, которую пытаются повысить различными методами, ограничения по сложности моделей мира, сложности в интерпретации результатов, зависимость качества обучения от начальных условий обучения и т.п.

Отметим, что для логических методов искусственного интеллекта обучение с подкреплением развито значительно слабее. Автором был предложен подход к обучению с учителем в задачах обучения роботов [Добрынин, 2006]. В работе [Добрынин, 2021] автором была предложено развитие данного метода, использующее идеи “reinforcement learning” для построения самообучающейся системы. Эксперименты на симуляторе роботов показали, что качество обучения сильно зависит от начальных условий. Это связано с тем, что в процессе обучения случайно полученные «плохие» гипотезы остаются в системе и мешают получить гипотезы, необходимые для хорошего поведения робота.

В настоящей работе описывается подход, который направлен на устранение этих недостатков. Для этого в систему управления роботом вводится специальный механизм удаления «плохих» гипотез.

1. Модельная задача

Кратко опишем модельную задачу, ранее использованную в работе [Добрынин, 2021].




Рис. 1. Модель робота и модель полигона

Для обучения робота используется задача движения робота по черной полосе (рис. 1) на ограниченном полигоне. Из-за своей простоты эта задача входит в состав многих соревнований мобильных роботов. Несмотря на внешнюю простоту, движение по линии является хорошим примером динамической среды, так как сам робот двигается по полигону.

Набор возможных действий робота ограничивается движением вперед и поворотами. Робот (рис. 1) представляет собой трехколесную тележку с дифференциальными колесами и одним опорным колесом. Для обнаружения полосы робот имеет четыре датчика. Количество датчиков полосы можно варьировать. На рис. 1 цифрами обозначены номера датчиков.

Для определения текущего состояния робота используется сенсорная информация – состояние датчиков полосы, и вектор управления – состояние приводов робота. Отметим, что эта информация не является полной для описания состояния всей системы робот-полигон. Для полного описания состояния всей системы необходимо дополнительно учесть взаимное положение робота и полосы, характер изменения полосы при движении робота. Использование неполной информации, которой владеет робот, является характерным случаем для робототехники.

Текущее состояние в терминах ДСМ-системы [Добрынин, 2021] представляет собой один пример, который имеет следующее представление:

$$P_i = (S_i, C_i),$$

где S_i – вектор сенсорной информации, который включает в себя всю текущую информацию о состоянии датчиков;

C_i – вектор управления, который включает в себя всю текущую информацию о состоянии приводов.

Каждый датчик полосы кодируется двумя битами:

{1 0} – не видит полосу,

{0 1} – видит полосу.




Рис. 2. Структура примеров и гипотез

Такое представление используется в операции пересечения над битовыми строками. На рис. 2 приведен пример возможного представления одного примера. Надчеркивание над номером датчика означает инверсию состояния.

Особенностью представления вектора управления является тот факт, что он может содержать единицу только в одной позиции, соответствующей определенному движению робота. В данной модели используются четыре заранее определенных движения робота: вперед (Forward), назад (Backward), влево (Left) и вправо (Right). Этих движений достаточно для выполнения задачи – движения по полосе. Для удобства структура гипотезы имеет тот же вид, что и пример.

2. SORL метод

SORL (Similarity Operation Reinforcement Learning) является продолжением развития идей динамического ДСМ метода в область самообучения без учителя. Накопившиеся изменения оказались столь значительны, что потребовалось выделение этого метода в отдельный класс. Динамический ДСМ метод был предложен в работе [Добрынин, 2006]. В отличие от классического ДСМ метода [Финн, 1991], [Финн, 2020], SORL метод может быть использован в открытой среде с неполной информацией и с неизвестным заранее количеством примеров. Классический ДСМ метод использует базу знаний, сформированную с помощью экспертов. Он хорошо работает в таких областях, как социология, медицина, фармакология и др., где можно собрать достаточную обучающую выборку. В настоящее время ДСМ метод активно развивается [Виноградов, 2018], [Финн, 2020]. Для робототехники использование классического ДСМ метода затруднительно, поскольку робот действует в изменяющейся среде и сбор информации о внешнем мире необходимо автоматизировать.

В ходе работы SORL метода (как и ранее динамического ДСМ метода) база знаний является открытой и формируется в ходе обучения робота, т.е. по мере поступления новой информации. Это свойство SORL метода дает возможность использовать данный метод для построения систем управления интеллектуальным роботом, способным обучаться самостоятельно.

3. Самообучение SORL системы

Кратко рассмотрим обучение системы управления интеллектуальным роботом, ранее описанную в [Добрынин, 2021].

Предположим, что начальный момент времени база (+)гипотез робота пуста (рис. 3). Тогда первый пример, сформированный из сенсорной информации, не будет распознан и система управления перейдет в режим классификации (t)примера. Для этого используется блок, выделенный на рис. 3 как конструктор гипотез. Для нового неизвестного примера необходимо случайным образом сформировать вектор управления. При этом сначала ищутся отрицательные гипотезы, которые вкладываются в текущий вектор сенсоров. Если такие гипотезы найдены, то соответствующие

Для определения качества действия вводится целевая функция (Target), которая будет выдавать информацию о том, достиг робот поставленной цели или не достиг. Достижение цели можно определить по вектору сенсоров. Целевая функция определяется как:

$T(S_i) = 1$ (true), в случае, если цель достигнута.

$T(S_i) = 0$ (false), в случае, если цель не достигнута.

Классификация примеров для вектора сенсоров S_i проводится следующим образом:

1) $S_i \triangleleft S_i'$, $T(S_i) = 0$, $T(S_i') = 0$, пример $\rightarrow P(-)$

2) $S_i \triangleleft S_i'$, $T(S_i) = 0$, $T(S_i') = 1$, пример $\rightarrow P(+)$

3) $S_i \triangleleft S_i'$, $T(S_i) = 1$, $T(S_i') = 0$, пример $\rightarrow P(+)$

4) $S_i \triangleleft S_i'$, $T(S_i) = 1$, $T(S_i') = 1$, пример $\rightarrow P(+)$

5) $S_i = S_i'$, $\text{timeout} = \text{true}$, пример $\rightarrow P(-)$, $\text{robot} \rightarrow \text{home}$

Заметим, что приведенные правила классификации примеров не являются очевидными. Например, в правиле 3 робот двигался по полосе ($T(S_i)=1$) и полосу потерял ($T(S_i')=0$). В этом случае пример будет отнесен к положительным примерам, хотя в результате действия целевая функция оказывается не выполненной. Эксперименты на симуляторе показывают, что в данной ситуации отнесение к отрицательным примерам дает худший результат, чем отнесение к положительным примерам. Можно предположить, что потеря полосы в данном случае не является плохим, поскольку могла произойти от не зависящим от робота обстоятельствам. Например, робот двигался прямо по полосе, но встретил поворот (о котором он не знал заранее).

Такие неопределенности говорят о неполноте информации, которая служит для принятия решения. Напомним, что робот обладает лишь частью информации, которая описывает состояние системы робот-полигон.

Эксперименты на симуляторе показали, что качество обучения сильно зависит от начальных условий – положения робота относительно полосы и начального значения датчика случайных чисел. Из-за этого в процессе обучения случайно полученные «плохие» гипотезы остаются в системе и мешают получить гипотезы, необходимые для хорошего поведения робота. Полученные наборы гипотез для разных запусков процедуры обучения оказываются разными [Добрынин, 2021]. Этот факт еще раз доказывает, что модельная задача движения по полосе, несмотря на кажущуюся простоту, является довольно сложной динамической средой.

4. Самообучение с коррекцией ошибок

Для улучшения формируемых гипотез необходим механизм, уstraняющий «плохие» гипотезы из базы правил. Тогда взаимная работа по созданию новых гипотез из случайных действий и устранению плохих гипотез должна привести к лучшим результатам.

Для оценки «плохих» гипотез введем функцию штрафа (Penalty)
 $P(S_i) = 1$ (true) в случае, если обнаружен «плохой» результат
 $P(S_i) = 0$ (false) в случае, если не обнаружен «плохой» результат
 Определение «плохого» результата в общем случае является не тривиальной задачей. В простейшем случае можно предположить, что если цель не достигнута, то обнаружен «плохой» результат:

$$P(S_i) = \text{not } T(S_i).$$

Как было показано ранее, из-за неполноты информации для принятия решения, это допущение не всегда выполняется. Поэтому данное условие необходимо дополнять другими условиями.

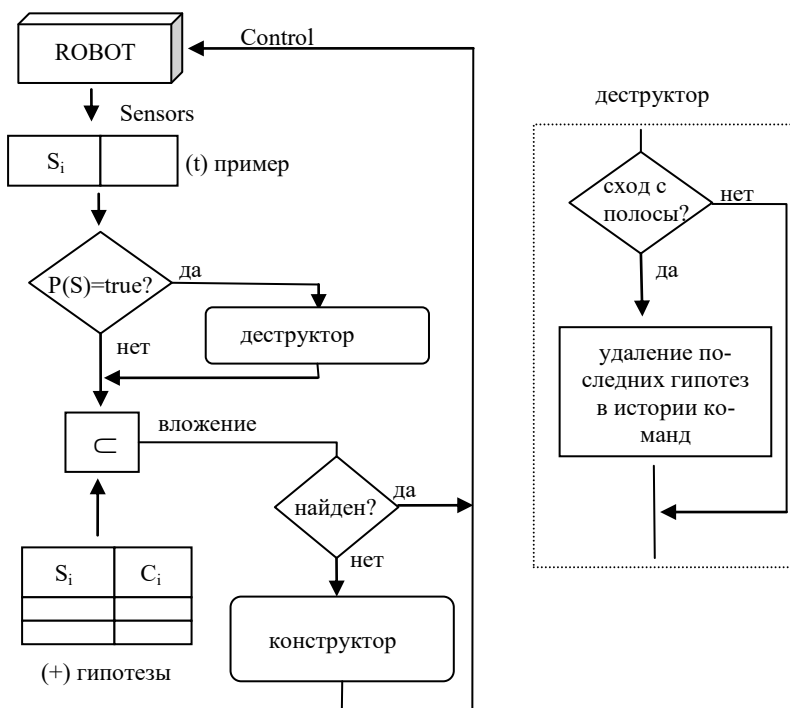


Рис. 4. Самообучение с коррекцией ошибок

Конструктор гипотез в данной системе выполняет те же функции, что и ранее (рис. 3, 4).

Для устранения «плохих» гипотез из базы фактов в систему управления (рис. 4) вводится деструктор гипотез. Он работает после считывания сенсорной информации, когда функция штрафа принимает истинное значение.

При движении робота по полосе гипотезы работают не по одной, а следуют друг за другом (рис. 5). При этом применение гипотезы приводит к состоянию, отличному от предыдущего состояния. При наличии двух гипотез, они будут выполняться друг за другом. Состояние датчиков при этом будет меняться циклически.




Рис. 5. История команд и состояний при возникновении ошибки

Плохие гипотезы приводят к возникновению цепочек гипотез, которые вызывают сход с полосы и возникновение тайм-аута. Одним из возможных решений в данном случае будет удаление всех или части гипотез, входящих в цепочку, которая приводит к сходу с полосы.

Для экспериментов по моделированию использовалось удаление последней гипотезы в цепочке гипотез, которые приводили к сходу с полосы. Примеры, которые породили данную гипотезу, также удалялись. Отрицательные гипотезы также удалялись. Такой способ устранения «плохих» гипотез приводит к разрыванию плохих цепочек.

5. Результаты моделирования

Для моделирования движения робота по полосе был использован симулятор роботов (рис. 1). Выше было отмечено, что результат самообучения в предыдущих экспериментах зависит от начального положения робота и начального значения датчика случайных чисел. Поэтому для сравнения результатов обучения с коррекцией ошибок и без нее, фиксировалось начальное положение робота и начальное значение датчика случайных чисел для одной серии экспериментов. Целевая функция задавалась для каждого примера своя.

Пример 1.

Целевая функция $T(S_i)$:

```
if Photo2 then true
    else false
endif
```

Если фотодатчик 2 видит полосу, то функция выдает значение true, иначе выдает false.

В табл. 1 приведены результаты двух экспериментов для данной целевой функции.

Для эксперимента 1 результаты обучения без коррекции ошибок и с коррекцией полностью совпали. Это объясняется тем, что удаление гипотез происходит только при возникновении схода с полосы. Поскольку в этом эксперименте сразу были получены хорошие гипотезы (так сложились обстоятельства), то удаления не было.

Таблица 1

	Эксперимент 1 без коррекции и с коррекцией ошибок	Эксперимент 2 без коррекции ошибок	Эксперимент 2 с коррекцией ошибок
	$\bar{1}1 \bar{2}2 \bar{3}3 \bar{4}4$ FB LR	$\bar{1}1 \bar{2}2 \bar{3}3 \bar{4}4$ FB LR	$\bar{1}1 \bar{2}2 \bar{3}3 \bar{4}4$ FB LR
(+) примеры	01 00 10 10 0 0 0 1 10 01 00 10 0 0 1 0 00 01 00 00 0 0 0 1	00 01 01 10 0 0 1 0 00 01 00 00 0 0 0 1 00 00 00 10 0 0 0 1	00 01 01 10 0 0 1 0 10 10 00 00 0 0 0 1
(-) примеры	10 10 00 00 0 0 1 0 10 10 00 01 1 0 0 0 10 10 00 00 0 0 0 1 10 10 10 00 1 0 0 0	10 10 00 01 0 0 0 1 10 10 00 01 0 0 1 0 10 10 00 01 1 0 0 0 00 10 10 01 1 0 0 0 01 10 00 01 1 0 0 0	
	хорошо	плохо	хорошо

Эксперимент 2 без коррекции ошибок дает плохой результат – робот часто сходит с полосы. В этом эксперименте по стечению обстоятельств были сразу получены плохие гипотезы – вторая и третья, которые приводили к этому эффекту. Одновременно они вызывали заикливание процесса обучения. При коррекции ошибок деструктор удалил эти гипотезы. В результате дальнейшего обучения была сгенерирована дополнительная гипотеза, которая исправила положение.

Пример 2.

Целевая функция T(Si):

```
if Photo1 OR Photo2 OR Photo3 OR Photo4
then true
else false
endif
```

Если любой из фотодатчиков видит полосу, то функция выдает значение true, иначе выдает false.

Результаты некоторых экспериментов приведены в табл. 2.

В эксперименте 3 также не было получено различий между результатами обучения с коррекцией ошибок и без нее. Видимо сразу были получены гипотезы, которые хорошо работали и робот не сходил с полосы. При этом коррекция гипотез не выполнялась.

Таблица 2

	Эксперимент 3 без коррекции и с коррекцией ошибок	Эксперимент 4 без коррекции ошибок	Эксперимент 4 с коррекцией ошибок
	$\bar{1}1 \bar{2}2 \bar{3}3 \bar{4}4$ FB LR	$\bar{1}1 \bar{2}2 \bar{3}3 \bar{4}4$ FB LR	$\bar{1}1 \bar{2}2 \bar{3}3 \bar{4}4$ FB LR
(+) примеры	10 00 00 00 0 0 1 0 01 00 00 00 0 0 0 1	00 01 00 00 1 0 0 0 00 10 00 00 0 0 1 0	00 10 00 00 0 0 1 0 00 01 00 00 0 0 0 1 01 00 00 00 0 0 0 1
	хорошо	плохо	хорошо

В эксперименте 4 без коррекции ошибок получились плохие правила, которые уводили робота с полосы. При этом робот двигался вперед и вправо. Коррекция ошибок убрала плохое правило. При дальнейшем обучении возникли новые правила, которые привели к устойчивому движению по полосе.

Заметим, что в этой серии экспериментов отсутствуют отрицательные примеры. Видимо, это связано с тем, что целевая функция очень «мягкая» (любой датчик видит полосу). При этом отрицательные примеры не возникают, поскольку целевая функция практически всегда выполняется.

Заключение

Обучение с подкреплением для логических методов искусственного интеллекта, таких как SORL, позволяет расширить их область применения. Применение механизма удаления плохих гипотез позволяет уменьшить зависимость качества получаемых гипотез от начальных условий обучения. Отметим, что предложенный механизм улучшения качества обучения не является единственно возможным. Работа в этом направлении требует дальнейшего развития.

Отметим, что обучение с подкреплением на основе SORL метода обладает высокой скоростью обучения. Практически робота можно учить в реальном времени во время работы на полигоне. Поскольку для получения одной гипотезы достаточно двух похожих примеров, пополнение базы знаний происходит за несколько похожих случаев.

Предложенный подход к обучению с подкреплением для SORL метода может быть использован для построения эффективно обучаемых систем управления интеллектуальными роботами. Очевидно, что этот подход требует дальнейшего развития.

Список литературы

- [Moerland, 2020] Moerland T.M., Broekens J., Jonker C.M. Model-based Reinforcement Learning: A Survey. – 2020. – P. 421-429.
- [Sutton, 2018] Richard S. Sutton, Andrew G. Barto Reinforcement learning: an introduction. Second edition. – MIT Press, Cambridge, MA, 2018.
- [Виноградов, 2018] Виноградов Д.В. Вероятностно-комбинаторный формальный метод обучения, основанный на теории решеток: дисс. на соиск. уч. ст. д.ф.м.н. по спец. 05.13.17 Теор. основы информ. – М.:ФИЦ ИУ РАН, 2018. – 131 с. – URL: http://www.frccsc.ru/diss-council/00207305/diss/list/vinogradov_dv.
- [Добрынин, 2006] Добрынин Д.А. Динамический ДСМ-метод в задаче управления интеллектуальным роботом // Десятая национальная конференция по искусственному интеллекту КИИ-2006, 25-28 сентября 2006 г., Обнинск: Труды конференции. – М.: Физматлит 2006. Т. 2.
- [Добрынин, 2021] Добрынин Д.А. Обучение с подкреплением в задаче управления интеллектуальным роботом // Сборник научных трудов X-й Международной научно-технической конференции (ИММВ-2021, Коломна, 17-20 мая 2021 г.). В 2-х т. Т. 2. – Смоленск: Универсум, 2021. – С. 6-15
- [Финн, 1991] Финн В.К. Правдоподобные рассуждения в интеллектуальных системах типа ДСМ // Итоги науки и техники. Сер. «Информатика». Т. 15. – М.: ВИНТИ, 1991.
- [Финн, 2020] Автоматическое порождение гипотез в интеллектуальных системах / под общ. ред. В.К. Финна. – М.: Книжный дом «ЛИБРОКОМ», 2020. – 2-е изд. стереотип.

УДК 004.891.3

ИНТЕГРАЦИЯ МЕТОДОВ СИСТЕМНОГО АНАЛИЗА И КОГНИТИВНОЙ ГРАФИКИ ПРИ РАННЕЙ ДИАГНОСТИКЕ ПАТОЛОГИЙ ЗРЕНИЯ*

А.П. Еремеев (*eremeev@appmat.ru*)

О.С. Колосов (*KolosovOS@mpei.ru*)

Национальный исследовательский университет «МЭИ», Москва

М.В. Зуева (*visionlab@yandex.ru*)

И.В. Цапенко (*sunvision@mail.ru*)

НМИЦ глазных болезней им. Г. Гельмгольца, Москва

В работе рассматриваются возможности компьютеризации ранней диагностики сложных патологий зрения на примере заболеваний сетчатки. В качестве исходных данных для интеллектуального анализа используются данные медицинского прибора электроретинографа, которые обрабатываются с помощью методов анализа сложных систем (разложение в ряд Фурье, спектральный анализ, анализ изменений амплитудно- и фазо-частотных характеристик сетчатки в разных режимах тестирования), методов искусственного интеллекта (нечеткой логики, продукционных правил, формируемых на основе знаний экспертов-физиологов) и методов когнитивной графики для образного представления состояний сетчатки. Работа проводится специалистами НИУ «МЭИ» и НМИЦ ГБ им. Гельмгольца в плане разработки интеллектуальной системы поддержки принятия решений для ранней диагностики патологий.

Ключевые слова: искусственный интеллект, сложная система, когнитивная графика, патология зрения, диагностика.

Введение

Известно, что системы поддержки принятия решений (Decision Support Systems, СППР) предназначены для помощи человеку – лицу, принимающему решения (ЛПР), при поиске наилучшего (оптимального, если это возможно в сложившейся ситуации) или приемлемого решения при воз-

* Работа выполнена при финансовой поддержке РФФИ (проект № 20-07-00498 А).

никновении проблемной ситуации в условиях различного типа неопределенности (например: неточности, нечеткости, неполноты, противоречивости имеющейся информации), а также зачастую в условиях достаточно жестких ограничений на время поиска решения. Использование классических методов математической оптимизации в этом случае практически невозможно или малопродуктивно. Поэтому необходимо применение методов искусственного интеллекта в сочетании со знаниями специалистов-экспертов в данной предметной/проблемной области, т.е. создание интеллектуальных СППР (ИСППР).

Применительно к медицине ИСППР можно разделить на два класса [Кобринский, 2022]:

- интеллектуальные системы для поддержки клинической медицины, ориентированные на помощь медикам (т.е. непосредственно ЛПР);
- рекомендательные медицинские системы на основе искусственного интеллекта, ориентированные на помощь (рекомендации) пациентам.

В данной работе речь идет о разработке ИСППР первого типа для ранней диагностики сложных патологий зрения с применением методов системного анализа и искусственного интеллекта (нечеткой логики и когнитивной графики) на примере заболеваний сетчатки глаза.

Ранняя диагностика патологий зрения неизбежно сталкивается с рядом хорошо известных проблем, главной из которых является надежное выявление тенденции изменения состояния диагностируемого пациента. Выявление такой тенденции, естественно, связано с некоторым периодом наблюдения за состоянием пациента. Сокращение такого периода в ранней диагностике имеет принципиальное значение. В свою очередь, состояние пациента оценивается по целому ряду признаков, каждый из которых характеризуется вполне конкретным диапазоном значений, соответствующим тому или иному диагнозу. Специфика ранней диагностики обусловлена тем, что все упомянутые диапазоны как бы пристыкованы к диапазонам допустимых значений признаков нормально функционирующего глаза и требуется надежно зафиксировать момент перехода значения того или иного признака из области, соответствующей состоянию нормально функционирующего глаза, в область определенной патологии. При таком переходе соответствующее значение признака может принадлежать сразу нескольким возможным диапазонам разных патологий (возникает неопределенность типа нечеткости). Задача диагностики осложняется также тем, что в то же время какие-то признаки могут оставаться в диапазонах нормы. Поэтому требуется введение определенных степеней соответствия, за коррекцией которых необходимо следить при повторных обследованиях, чтобы поставить окончательный диагноз.

Все обсуждаемые вопросы в контексте создания ИСППР ранней диагностики в данной работе связаны непосредственно с данными электроретинографических обследований субъектов (пациентов) как с нормальным зрением, так и с различными патологиями. Однако опыт создания прототипа ИСППР на базе нечеткой логики [Anisimov et al., 2013], которая достаточно успешно применяется при построении нечетких логических регуляторов (НЛР) [Mamdani et al., 1975], указывает на необходимость учета специфики именно ранней диагностики при создании ИСППР. Действительно, задача ранней диагностики при большом числе возможных патологий, в отличие от НЛР, приводит к необходимости поиска новых формализованных признаков патологий путем дополнительных формальных преобразований имеющихся экспериментальных данных. К таким преобразованиям относятся спектральный анализ и вейвлет-преобразования [Hastie et al., 2001; Dembele et al., 2003; Eremeev et al., 2019; Phinyomark et al., 2011; Mallat, 2009; Lilly et al., 2010] различных видов электроретинограмм (ЭРГ), регистрируемых в процессе электроретинографических [De Rouck, 2006] обследований пациентов.

Специфика ИСППР для ранней диагностики патологий зрения осложнена ограниченностью статистического материала и необходимостью неоднократного проведения обследований для постановки окончательного диагноза. Такие условия не позволяют эффективно воспользоваться искусственными нейронными сетями (ИНС) и известными приемами кластеризации, базирующимися на статистических методах [Hastie et al., 2001; Dembele et al., 2003], хотя при определенных условиях применение ИНС для анализа и диагностики патологий зрения вполне целесообразно [Еремеев и др., 2020].

1. Преобразование ЭРГ для расширения признакового пространства

Весьма серьезной проблемой, сдерживающей внедрение цифровых технологий в создание ИСППР ранней диагностики, остается недостаточное число информативных признаков, извлекаемых из ЭРГ, несмотря на большее число видов самих ЭРГ. Этим объясняется обилие публикаций на тему преобразования ЭРГ с целью расширения признакового пространства [Phinyomark et al., 2011; Mallat, 2009; Lilly et al., 2010; De Rouck, 2006]. Однако стремление многих исследователей воспользоваться вейвлет-преобразованиями достаточно ощутимых результатов пока не приносит. В тоже время разложение ЭРГ как периодической функции в ряд Фурье позволяет на основе получаемых амплитудных и фазовых спектров определить амплитудно-частотные и фазо-частотные характеристики (АЧХ и ФЧХ) непосредственно самой сетчатки для данных конкретных условий

тестирования [Zueva et al., 2019]. Установлено, что максимальные значения частот гармоник АЧХ и ФЧХ не должны превышать 120–150 Гц. Приведение всех АЧХ и ФЧХ к единой псевдочастоте (за счет искусственного удлинения периода) позволяет проследить изменение параметров каждой гармоники в разложениях в зависимости от частоты подачи световых вспышек [Anisimov et al., 2013; Zueva et al., 2019; Александрова и др., 2021]. Это особенно важно при анализе ритмических ЭРГ (РЭРГ). На рис. 1. приведена АЧХ сетчатки субъекта (пациента) с нормой зрения по результатам обработки фотопической РЭРГ при частоте вспышек 8.3 Гц (единая псевдочастота 4.15 Гц).

Амплитуда каждой гармоники АЧХ – это коэффициент преобразования самой сетчатки на этой частоте. АЧХ нормируют относительно здорового глаза и поэтому оцифровка оси ординат производится в относительных единицах. Анализ свыше 1000 подобных АЧХ для разных состояний сетчатки позволяет выделить две характерные области частот гармоник на АЧХ и ФЧХ. Границей этих областей является гармоники в окрестности 50 ± 5 Гц.




Рис. 1. АЧХ сетчатки субъекта с нормой зрения при частоте вспышек 8.3 Гц (единая псевдочастота 4.15 Гц)

В области высоких частот (ВЧ) с частотами гармоник свыше 50 Гц АЧХ проще всего аппроксимировать константой, которая задает среднее значение амплитуд гармоник. Область низких частот, в свою очередь, условно можно разделить на две подобласти: подобласть инфранизких частот (до 15-20 Гц), зависимую от величины фазы первой гармоники в спектре разложения РЭРГ, и независимую от фазы первой гармоники подобласть (20-50 Гц), которую мы далее будем называть областью НЧ. Таким образом: область НЧ – это гармоники в диапазоне 20-50 Гц; область ВЧ – это гармоники в диапазоне 50-80 Гц.

Для этих областей оцениваются площади под кривыми, которые однозначно связываются со средними значениями амплитудных значений АЧХ на этих участках. На их основе предложены 4 признака:

- НЧ – абсолютный признак;
- ВЧ – абсолютный признак;
- НЧ×ВЧ – абсолютный признак;
- НЧ/ВЧ – относительный признак.

Кроме этих признаков рассматривается также максимум АЧХ и еще 2 признака, извлекаемые из ФЧХ – это начальная фаза первой гармоники (размерность в радианах) и наклон графика ФЧХ в области НЧ (размерность рад/Гц). В этой области график ФЧХ с высокой точностью аппроксимируется полиномом первого порядка. Оба признака, извлекаемые из ФЧХ, могут считаться относительными (как и признак НЧ/ВЧ).

Таким образом, из каждой ЭРГ извлекается 7 признаков на каждой из 5 частот подачи импульсов для РЭРГ. Кроме этого, в работе [Александрова и др., 2021] показана возможность получения таких же признаков при обработке общей ЭРГ с учетом того, что световые вспышки в этом режиме следуют с частотой 1 Гц.

Наибольший интерес для исследований с введенными признаками представляют фотопические РЭРГ. У физиологов существует, условно говоря, своя биологическая модель сетчатки, согласно которой каждая частота подачи световых вспышек активизирует определенные группы клеток и нейронов, а их активность может ассоциироваться с определенными видами патологий [Зуева и др., 2009]. Однако во временной области фиксируется всего один параметр РЭРГ – ее размах, что явно недостаточно для качественной диагностики.

При проведении исследований были сформированы 4 группы субъектов – 3 группы с разными патологиями (глаукома (Гл), диабетическая ретинопатия (Др), возрастная макулярная дистрофия (ВМД)) и 1 группа с нормой зрения. В каждой группе анализировались 10 глаз. Всего было проанализировано 200 РЭРГ и для каждой определено по 7 признаков. Для 3 введенных относительных признаков определены средние значения в группах и диапазоны изменения соответствующего признака для патологии в этой группе. Далее производилось попарное сравнение получаемых диапазонов изменения относительных признаков и их средних значений с соответствующими параметрами для нормы зрения. Получившиеся результаты будут рассмотрены в следующем разделе.

2. Применение методов нечеткой логики для ранней диагностики

Первые варианты построения прототипа ИСППР создавались для сравнительной диагностики определенного числа возможных патологий сетчатки глаза с использованием нечеткого логического вывода на основе правил Мамдани [Mamdani et al., 1975]. При этом для проведения этапа фаззификации использовались линейные функции принадлежности (ФП), показанные на рис. 2,а и обычно применяемые в НЛР. На рис. 2 символами S , M и B обозначены ФП для малых, средних и больших значений лингвистической переменной z ; γ – коэффициент, используемый для задания формы ФП в соответствующих соотношениях (2.1)–(2.3), приведенных ниже. Среднее значение лингвистической переменной z в границах $Z_{min} - Z_{max}$ обозначено как Z_0 .

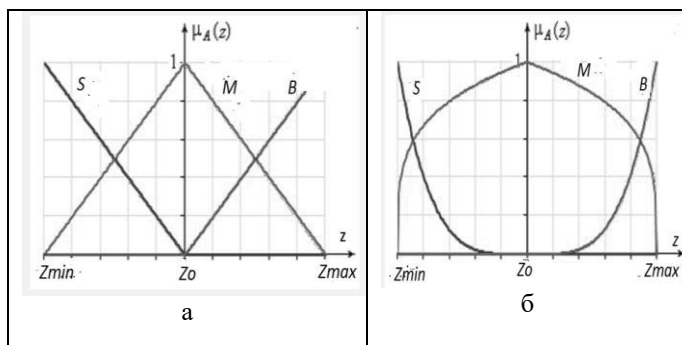


Рис. 2. Виды ФП: а - для НЛР ($\gamma = 1$); б - для ИСППР ($\gamma = 4$)

Следует отметить, что на этапе фаззификации оценивался общий диапазон возможных значений каждой лингвистической переменной (признака) z и на нем отмечались средние значения для каждой патологии. Такая процедура осуществляется для каждого признака. Результатом работы ИСППР с использованием нечеткого логического вывода, является набор степеней соответствия возможных патологий при предъявлении системе результатов обработки ЭРГ конкретного субъекта.

Первый прототип подобной ИСППР [Anisimov et al., 2013], помимо верных результатов диагностики, порой давал много так называемых «ложноположительных» результатов, т.е. в отдельных вариантах появлялись ложные заключения. Этому способствует ряд причин:

- ограниченные выборки для групп патологий, в результате чего непредсказуемо смещаются средние значения признаков патологий относительно границ их изменения в группе;
- линейный вид ФП (см. рис. 2,а), удобный для формирования статистической характеристики НЛР, приводит к появления ошибочных результатов из-за влияния перекрестных участков изменения признаков других групп патологий;
- большое число возможных патологий, рассматриваемых в общих границах изменения z одновременно всех признака из-за их наложений и пересечений.

Исследования показывают, что для ИСППР линейный вид ФП (см. рис. 2,а) следует специальным образом трансформировать в средней части изменения лингвистической переменной z , как это показано на рис. 2,б, посредством введения коэффициента γ . Аналитические зависимости для расчетов ФП термов представлены следующими формулами (2.1)–(2.3):

«Малое - S »:

$$\mu_{A^1}(z) = \begin{cases} 1, & z < Z_{min} \\ \left(\frac{Z_0 - z}{Z_0 - Z_{min}} \right)^\gamma, & Z_{min} \leq z \leq Z_0 \\ 0, & z > Z_0 \end{cases} \quad (2.1)$$

«Среднее - M »:

$$\mu_{A^2}(z) = \begin{cases} 0, & z < Z_{min} \\ \left(\frac{z - Z_{min}}{Z_0 - Z_{min}} \right)^{1/\gamma}, & Z_{min} \leq z \leq Z_0 \\ \left(\frac{Z_{max} - z}{Z_{max} - Z_0} \right)^{1/\gamma}, & Z_0 \leq z \leq Z_{max} \\ 0, & z > Z_{max} \end{cases} \quad (2.2)$$

«Большое B »:

$$\mu_{A^3}(z) = \begin{cases} 0, & z < Z_0 \\ \left(\frac{z - Z_0}{Z_{max} - Z_0} \right)^\gamma, & Z_0 \leq z \leq Z_{max} \\ 1, & z > Z_{max} \end{cases} \quad (2.3)$$

Коэффициент γ – это степень, в которую возводятся ФП крайних термов. ФП среднего терма при этом автоматически возводится в степень $1/\gamma$. Степень γ целесообразно выбрать в диапазоне (4-8). В этом варианте средние значения ФП представляют собой своеобразный «колпак» (рис. 3).

Значения ФП относительно медленно убывают по мере отхода от среднего значения признака Z_0 , не доходя в пределах 5–10% до границ общего диапазона изменения признака z , и резко убывают до нуля, достигая границ этого диапазона. Очевидно, что если имеется одна патология в заданных границах изменения лингвистической переменной со средним значением Z_0 , то использование максиминного базиса (правило Мамдани) приведет к оценке степени соответствия этой патологии через соотношение (2.2).

На рис. 3 представлены совмещенные графики ФП признака «коэффициент наклона (k) ФЧХ» для нормы зрения и ВМД для двух частот следования световых вспышек: 10 Гц и 12 Гц, цифрой 1 помечены ФП для ВМД.




Рис. 3. Совмещенные графики ФП признака «коэффициент наклона (k) ФЧХ» для нормы зрения и ВМД для двух частот стимуляции: а – 10 Гц, б – 12 Гц

Из рис. 3 видно, что патология ВМД может быть зафиксирована в том случае, если признак патологии вышел за границу общей зоны нормы зрения и ВМД. Фактически процесс ранней диагностики может быть сведен к просмотру совмещенных графиков ФП средней зоны признаков нормы зрения и возможных патологий для одноименных ЭРГ. При этом те признаки конкретного субъекта, которые оказываются в общей зоне нормы зрения и патологии, считаются относящимися к норме. Что касается абсолютных признаков, которые рассматривались выше, то они используются для коррекции результатов с учетом возраста субъекта, степени патологии и пр.

Однако, оцениваемые при этом степени соответствия нуждаются в еще одной корректировке, так как общая зона изменения признака для нормы зрения и для предполагаемой патологии фактически соответствует норме зрения. Это происходит потому, что, как правило, патология на ранней стадии развивается не одновременно на оба глаза. В связи с этим диапазон изменения признака патологии следует сократить на величину, попадаю-

стью в диапазон изменения признака для нормы зрения. В этом случае диапазоны изменения признака нормы зрения и патологии оказываются пристыкованными друг к другу. Такая стыковка может оказаться как справа, так и слева от границ изменения признака z для нормы зрения.

Рассмотрим такую стыковку слева. Обозначим значения признака патологии, находящиеся в этой зоне как $z1$. Очевидно, что ФП этой зоны должны содержать всего две ФП: значение «Малое – $S1$ » и значение «Большое – $B1$ ». Расчет ФП производится по следующим соотношениям (2.4), (2.5):

«Малое - $S1$ »:

$$\mu_{A^1}(z1) = \begin{cases} 1, & z1 < Z1_{min} \\ \left(\frac{Z1_{max} - z1}{Z1_{max} - Z1_{min}} \right)^{\gamma}, & Z1_{min} \leq z1 \leq Z1_{max} \\ 0, & z1 > Z1_{max} \end{cases} \quad (2.4)$$

«Большое - $B1$ »:

$$\mu_{A^2}(z1) = \begin{cases} 0, & z1 < Z1_{min} \\ \left(\frac{z1 - Z1_{min}}{Z1_{max} - Z1_{min}} \right)^{\gamma}, & Z1_{min} \leq z1 \leq Z1_{max} \\ 1, & z1 > Z1_{max} \end{cases} \quad (2.5)$$

Нетрудно заметить, что нечеткий логический вывод для оценки степени соответствия единственной диагностируемой патологии приводит к соотношению (2.4). На рис. 4 схематично показаны совмещенные ФП для патологии (слева) и нормы зрения (справа, пунктир).




Рис. 4. Совмещенные ФП для патологии (слева) и нормы зрения (справа, пунктир)

Все значения ФП для $S1$, которые находятся левее среднего значения $Z1_0$, на основании логического вывода оказываются постоянными и могут быть приведены к единице.

На рис.4 показана зона неопределенности, которую целесообразно вводить. Ширина этой зоны для $\gamma=6$ задается как 5% диапазона изменения признака для нормы зрения от среднего значения Z_0 до границы Z_{min} . В этом случае

$$\mu_A(0.05Z_0 - 0.95Z_{min}) = \mu_A(0.95Z_{max} + 0.05Z_0) \approx 0.7.$$

Если ввести обозначения:

$$\begin{aligned} 0.05Z_0 - 0.95Z_{min} &= Z_{min}^*, \\ 0.95Z_{max} + 0.05Z_0 &= Z_{max}^* \end{aligned} \quad (2.6)$$

то в соответствии с (2.6)

$$\mu_A(Z_{min}^*) = \mu_A(Z_{max}^*) \approx 0.7.$$

Отметим, что в зоне неопределенности производить оценки степеней соответствия не целесообразно.

Аналогичные рассуждения несложно провести, если диапазон изменения признака патологии пристыкован к правой границе диапазона изменения признака для нормы зрения.

3. Образное представление патологий сетчатки на основе данных ЭРГ

Как отмечено ранее, для получения информации о функциональном состоянии различных элементов сетчатки офтальмологами используются ЭРГ, представляющие собой графическое выражение биоэлектрической активности клеточных элементов сетчатки в ответ на световое раздражение (рис. 5) [Tsang et al., 2018; Hoffmann et al., 2021]. Каждый из компонентов ЭРГ генерируется различными структурами сетчатки.

Практика показывает, что качественно интерпретировать графики ЭРГ способны только эксперты – специалисты в области клинической физиологии зрения, для практикующих врачей-офтальмологов, не имеющих практики электроретинографии, эта информация сложна в восприятии.

Представление патологий сетчатки в виде когнитивных образов (КО) позволяет решить эту проблему [Еремеев и др., 2022].

Модель *когнитивного образа* (КО) определяется тройкой: $K = (X, R, F)$, где $X = \{C_i \mid i=1, 2, \dots, n\}$ – непустое множество концептов (объектов предметной области), $R = \{R_j \mid j=1, 2, \dots, m\}$ – семейство отношений на множестве X , F – множество функций интерпретации.




Рис. 5. Схематическое изображение максимальной ЭРГ:
 a_1 и a_2 – амплитуда a -волны; b_1 и b_2 – амплитуда b -волны;
 D – длительность b -волны; L – латентный период; T_b – время
 кульминации. По оси ординат указаны амплитуда волн ЭРГ,
 по оси абсцисс – длительность волн ЭРГ

Каждый концепт C_i определяется набором $C_i = (N_i, T_i, P_i, Ch_i, A_i)$, где N_i – имя концепта C_i , $P_i = \{C_i^k \mid k=1, 2, \dots, x\}$ – множество предков концепта C_i , $Ch_i = \{C_i^s \mid s=1, 2, \dots, y\}$ – множество потомков концепта C_i , $A_i = \{A_i^u \mid u=1, 2, \dots, q\}$ – список атрибутов концепта C_i . Каждый атрибут A_i^u концепта C_i определяется набором $A_i^u = (Na_i^u, Ta_i^u, Va_i^u)$, где Na_i^u – имя атрибута A_i^u , Ta_i^u – тип атрибута A_i^u , Va_i^u – значение атрибута A_i^u . T_i – тип концепта C_i , определяемый следующим образом: $T_i = (Nq_i, Aq_i, Mq_i, Pq_i)$, где Nq_i – имя типа концепта C_i ; $Aq_i = \{Aq_i^h \mid h=1, 2, \dots, r\}$ – список атрибутов типа концепта C_i ; $Mq_i = \{Mq_i^d \mid d=1, 2, \dots, f\}$ – список действий (методов) типа концепта C_i ; Pq_i – имя родительского типа концепта C_i .

Алфавитом (термами) в модели КО сетчатки является набор (множество) геометрических примитивов (точка, сплайн, эллипс, прямоугольник) $Aq_i = \{Aq_i^h \mid h=1, 2, \dots, r\}$. Формулой – один элемент слоя, состоящий из последовательности символов алфавита.

Аксиомы описывают построения элементов (элементарных КО) каждого вида:

- 1) образ «Палочка» состоит из 2-х эллипсов и находится в первом слое;
- 2) образ «Колбочка» состоит из 3-х эллипсов и находится в первом слое;
- 3) образ «Биполяр» состоит из прямоугольника и эллипса, занимающего 0.3 части от всего элемента, и находится во втором слое;
- 4) образ «Ганглиозная клетка» состоит из прямоугольника и эллипса, занимающего 0.8 части от всего элемента, и находится в третьем слое;
- 5) образ «Горизонтальная клетка» состоит из эллипса и сплайна и находится во втором слое;

б) образ «Амакриновая клетка» состоит из эллипса и находится во втором слое;

7) образ «Клетка Мюллера» состоит из прямоугольника и множества эллипсов 2-х видов и находится сбоку от всех других слоев.

Правила вывода определяют связи между элементами различных слоев:

1) образы «Палочка» и «Колбочка» могут быть связаны с элементами «Биполяр» и «Горизонтальная клетка»;

2) образы «Биполяр» и «Амакриновая клетка» могут быть связаны с элементом «Ганглиозная клетка»;

3) образ «Ганглиозная клетка» имеет связь, называемую «Аксон».

Множество концептов задаются следующим образом:

$C_1 = (\text{Палочка}, 0, \text{Биполяр (палочковый)}, A_1);$

$C_2 = (\text{Колбочка}, 0, \text{Биполяр (колбочковый)}, A_2);$

$C_3 = (\text{Биполяр (палочковый)}, \text{Палочка}, \text{Ганглиозная клетка}, A_3);$

$C_4 = (\text{Биполяр (колбочковый)}, \text{Колбочка}, \text{Ганглиозная клетка}, A_4);$

$C_5 = (\text{Ганглиозная клетка}, \text{Биполяр (палочковый)}, \text{Аксон}, A_5);$

$C_6 = (\text{Ганглиозная клетка}, \text{Биполяр (колбочковый)}, \text{Аксон}, A_6);$

$C_7 = (\text{Аксон}, \text{Ганглиозная клетка}, 0, A_7);$

$C_8 = (\text{Горизонтальная клетка}, \text{Палочка}, \text{Биполяр (палочковый)}, A_8);$

$C_9 = (\text{Горизонтальная клетка}, \text{Колбочка}, \text{Биполяр (колбочковый)}, A_9);$

$C_{10} = (\text{Амакриновая клетка}, \text{Биполяр}, \text{Горизонтальная клетка}, A_{10}).$

Для каждого концепта определяются список из 3-х атрибутов

$A_i = \{A_i^u \mid u=1,2,3\};$

$A_i^1 = (\text{Цвет}, 3 \text{ числа}, 0-255);$

$A_i^2 = (\text{Ширина}, \text{число}, W_i);$

$A_i^3 = (\text{Высота}, \text{число}, H_i).$

Аналогично вводится множество наборов показателей $P = \{P_i^h \mid h=1, 2, \dots, r\}$ в формате $P_i^h = (\text{Вид исследования}, \text{показатель}, \text{значение})$, например:

$P_i^1 = (\text{Максимальная ЭРГ}, Aa, 70-220)$ – показывает изменение в фоторецепторах (палочки и колбочки);

...
 $P_i^5 = (\text{Скотопическая ЭРГ}, Ab, 50-150)$ – показывает изменение в палочковых биполярных клетках;

...
 $P_i^7 = (\text{Фотопическая ЭРГ}, Aa, 14-44)$ – показывает изменение в колбочках;

$P_i^8 = (\text{Фотопическая ЭРГ}, Ta, 7-21)$ – показывает изменение в связях между колбочками и их биполярами;

...

P_i^{12} = (Осциляторные потенциалы, O1, 40-70) – показывает изменение в амакринах и обратных функциях связи от ганглиозных клеток к амакринам;

...
 P_i^{16} = (Паттерн ЭРГ stade state, A pik-to-pik, 50-120) – показывает изменение в ганглиозных клетках и аксоне;

P_i^{17} = (Паттерн ЭРГ, P50, 45-90) – показывает изменение в фоторецепторах и колбочковых биполярах;

...
Вычисления показателей производится на основе рекомендаций Международного общества клинической электрофизиологии зрения ISCEV [Hoffmann et al., 2021]: амплитуда Aa вычисляется от 0 до тах негативного; амплитуда Ab – от a до тах позитивного; время кульминации Ta – от оси до тах негативного; амплитуда A pik-to-pik – от тах негативного до тах позитивного; амплитуда $P50$ – от первого отрицательного отклонения до тах; $O1$ – от тах негативного до тах позитивного и т.д.

База знаний содержит набор продукционных правил. Левая и правая части правил – подсети семантической сети (универсума). Левая часть – набор показателей, правая – набор концептов с атрибутами.

Примеры продукционных правил:

Если P^1 (Максимальная ЭРГ, Aa , 60), то A_1^1 (100.100.70) (цвет тусклый);

Если P^1 (Максимальная ЭРГ, Aa , 100), то A_1^1 (150.150.79) (цвет умеренный);

Если P^1 (Максимальная ЭРГ, Aa , 150), то A_1^1 (200.220.100) (цвет яркий);

...
Если P^{14} (Фотопическая ЭРГ, Ab , 50), то A_3^1 (30.200.70) (цвет тусклый);
Если P^{14} (Фотопическая ЭРГ, Ab , 100), то A_3^1 (100.100.150) (цвет умеренный);

Если P^{14} (Фотопическая ЭРГ, Ab , 150), то A_3^1 (200.220.130) (цвет яркий).

Если выполняется левая (условная) часть правила, то правая часть (заключение) правила используется для построения КО сетчатки.

Для оценки состояния КО каждого вида фрагмента сетчатки, может быть использован комбинированный метод визуализации, заключающийся в изменении размера изображения и его цвета в зависимости от выбранных показателей.

Связь различных типов ЭРГ и КО представлена в виде онтологии на рис. 6. Примеры КО сетчатки в нормальном состоянии и при некоторых патологиях представлены на рис. 7. Нетрудно заметить, что некоторые КО (например, нижние КО для случаев преклинической и пролиферативной диабетической ретинопатии) недостаточно наглядны по причине наличия неполноты и неточности в исходной информации.

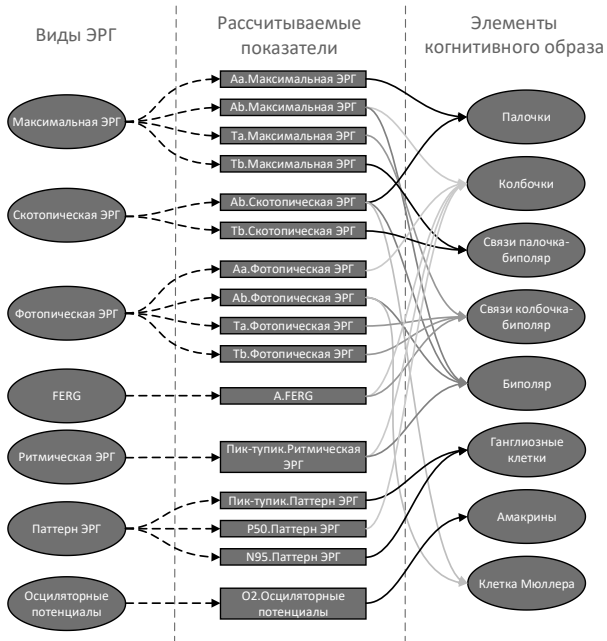


Рис. 6. Взаимосвязь видов ЭРГ и элементов КО

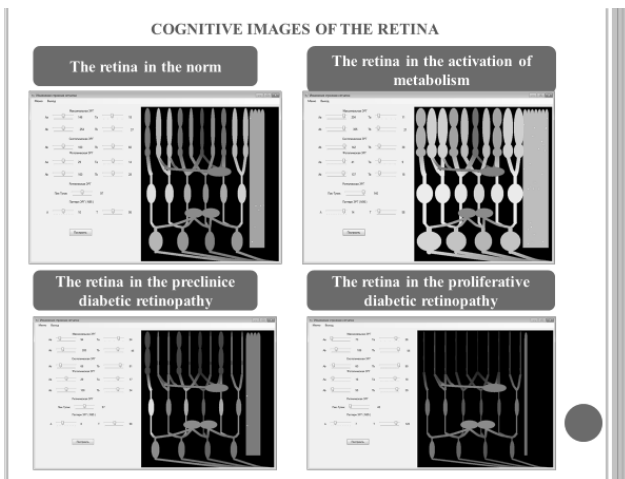


Рис. 7. Примеры КО сетчатки (без использования нечеткой логики)

Для повышения наглядности и информативности КО было предложено использовать метод построения КО с применением нечеткой логики (нечетких продукционных правил). Нечеткие продукционные правила имеют традиционный вид

$$\text{IF } (\beta_1 \text{ IS } \alpha_1) \text{ AND} \dots \text{ AND } (\beta_n \text{ IS } \alpha_n) \text{ THEN } (\beta_{n+1} \text{ IS } \alpha_{n+1}, k),$$

где β_i – соответствующие параметры (показатели), α_i – лингвистические значения, $i=1, \dots, n+1$, k – коэффициент правдоподобия (уверенности) значения α_{n+1} , $k \in [0, 1]$ (по умолчанию $k=1$).

Для нечеткого вывода был применен алгоритм Мамдани.

Приведем примеры лингвистических переменных для входных и выходных данных при построении КО:

“размер” – терм-множество: {малый, средний, большой}; носитель (универсум): интервал от минимального до максимального значения размера соответствующего КО;

“цвет” – терм-множество: {яркий, тусклый}; носитель (универсум): интервал от минимального до максимального значения цвета соответствующего КО;

“здоровье” – терм-множество: плохое, удовлетворительное (нормальное), хорошее}; носитель (универсум): интервал целых чисел от 20 до 100 (в %).

Универсум и функции принадлежности определены с помощью экспертов-физиологов. Приведем примеры нечетких продукционных правил для выходной переменной “здоровье” (в нотациях библиотеки FuzzyLogicLibrary):

- if (Size is small) or (Color is dim) then Health is bad;
- if (Size is big) or (Color is bright) then Health is good;
- if (Size is middle) or (Color is dim) then Health is bad;
- if (Size is big) or (Color is dim) then Health is normal.

Построенные с помощью нечеткой логики КО патологий сетчатки оказались более информативными и наглядными для медиков (рис. 8, 9).

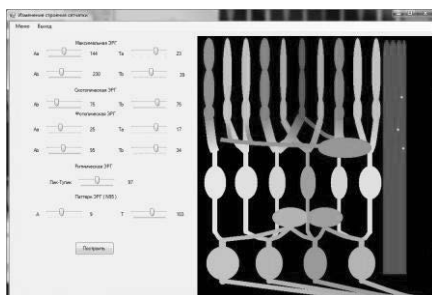


Рис. 8. Пример КО сетчатки при преκлинической диабетической ретинопатии

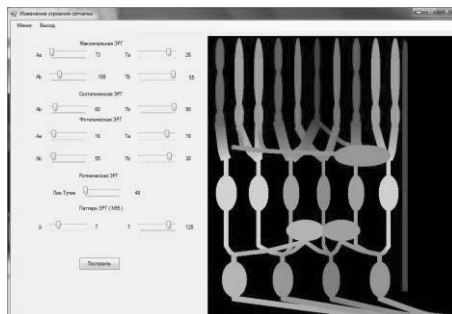


Рис. 9. Пример КО сетчатки при пролиферативной диабетической ретинопатии

Заключение

Разработана методика ранней диагностики патологий сетчатки глаза с применением методов анализа сложных систем и нечеткой логики, связанная с определением диапазонов признаков, характеризующих конкретные патологии и сопоставление их с диапазоном признаков, соответствующих норме зрения.

Данная методика опирается на нечеткий логический вывод, в результате чего определяется степень соответствия патологии по отношению к среднему значению, принимаемому за единицу. Ранняя диагностика предполагает несколько обследований субъекта (пациента) в течение определенного интервала времени с целью определения динамики изменения признаков во времени.

Полученные результаты также показали, что представление изменений функционального состояния сетчатки на основе КО с применением нечеткой логики существенно нагляднее, чем без ее применения. В дальнейшем планируется интеграция разработанных средств с другими методами анализа сложных систем и методами искусственного интеллекта, в частности, использование для ранней диагностики патологий каскадных сверточных нейронных сетей глубокого обучения.

Список литературы

- [Кобринский, 2022] Кобринский Б.А. Интеллектуальные рекомендательные системы для медицины // Искусственный интеллект и принятие решений. – 2022. – № 3.
- [Anisimov et al., 2013] Anisimov D.N., Vershinin D.V., Kolosov O.S., Zueva M.V., and Tsapenko I.V. Diagnosis of the Current State of Dynamic Objects and Systems with Complex Structures by Fuzzy Logic Using Simulation Models ISSN 0147_68 82. // Scientific and Technical Information Processing. – 2013. – Vol. 40, No. 6.
- [Mamdani et al., 1975] Mamdani E.H., Assilian S. An experiment in linguistic synthesis with fuzzy logic controller // Int. J. Man-Machine Studies. – 1975. – Vol. 7, No. 1.

- [Hastie et al., 2001] Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning. – Springer, 2001.
- [Dembele et al., 2003] Dembele D., Kastner P. C-means method for clustering microarray data // Bioinformatics. – 2003. – Vol. 19 (8).
- [Eremeev et al., 2019] Eremeev A.P. and Ivliev S.A. Data collection and preparation of training samples for problem diagnosis of vision pathologies // Sergei O. Kuznetsov, Aleksandr I. Panov (Eds.) // Communications in Computer and Information Science 1093. Artificial Intelligence. 17th Russian Conference, RCAI 2019. Ulyanovsk, Russia, October 21-25, 2019. – Springer, 2019.
- [Phinyomark et al., 2011] Phinyomark A., Limsakul C., and Phukpattaranont P. Application of wavelet analysis in EMG feature extraction for pattern classification // Measurement Science Review. – 2011. – Vol. 11, No. 2.
- [Mallat, 2009] S.G. Mallat, A Wavelet Tour of Signal Processing: The Sparse Way. Academic Press, Houston, Tex, USA, 3rd edition. 2009.
- [Lilly et al., 2010] Lilly J.M. and Olhede S.C. On the analytic wavelet transform // IEEE Transactions on Information Theory. – 2010. – Vol. 56, No. 8.
- [De Rouck, 2006] A.F. de Rouck, History of the electroretinography // In Principles and Practice of Clinical Electrophysiology of Vision, J.R. Heckenlively and G.B. Arden, Eds. – The MIT Press, London, UK, 2006.
- [Еремеев и др., 2020] Еремеев А.П., Ивлиев С.А. Методы и программные средства прототипа интеллектуальной системы поддержки принятия решений для анализа и диагностики сложных патологий зрения // Вестник МЭИ. – 2020. – № 5.
- [Zueva et al., 2019] Zueva M.V, Tsapenko I.V, Kolosov O.S, Vershinin D.V, Korolenkova V.A and Pronin A.D Assessment of the Amplitude-Frequency Characteristics of the Retina with Its Stimulation by Flicker and Chess Pattern-Reversed Incentives and their Use to Obtain New Formalized Signs of Retinal Pathologies // Biomedical Journal of Scientific & Technical Research. – 2019. – Vol. 19, No. 5.
- [Александрова и др., 2021] Александрова Ю.С, Баларев Д.А., Колосов О.С., Ови-вян А.В., Парфенова О.И. Приемы формирования признаковового пространства периодических временных зависимостей для систем диагностики динамических объектов на примере сетчатки глаза. // Вестник МЭИ. – 2021. – № 6.
- [Зуева и др., 2009] Зуева М.В., Нероев В.В., Цапенко И.В., Сарыгина О.И., Гринченко М.И., Зайцева С.И. Топографическая диагностика нарушений ретиальной функции при регматогенной отслойке сетчатки методом ритмической ЭРГ широкого спектра частот // Российский офтальмологический журнал. – 2009. – Т. 1 (№ 2).
- [Tsang et al., 2018] Tsang S.H, Sharma T. Electroretinography // Adv Exp Med Biol. – 2018. – 1085. – P. 17-20. – Doi: 10.1007/978-3-319-95046-4_5. PMID: 30578478.
- [Hoffmann et al., 2021] Hoffmann M.B, Bach M, Kondo M, Li S, Walker S, Holopigian K, Viswanathan S, Robson A.G. ISCEV standard for clinical multifocal electroretinography (mfERG) (2021 update) // Doc Ophthalmol. – 2021 Feb. – 142 (1). – P. 5-16. – Doi: 10.1007/s10633-020-09812-w.
- [Еремеев и др., 2022] Еремеев А.П., Цапенко И.В. Интеграция средств когнитивной графики и нечеткой логики для представления и диагностирования сложных патологий зрения // Интегрированные модели и мягкие вычисления в искусственном интеллекте: Сб. научн. тр. XI Международной научно-практ. конф. (ИММВ-2022, Коломна, 16-19 мая 2022 г.). В 2-х т. Т. 2. – М.: РАИИ. 2022.

УДК 681.51

УПРАВЛЕНИЕ ВИБРАЦИОННОЙ МАШИНОЙ НА ОСНОВЕ ЭВРИСТИЧЕСКОГО АЛГОРИТМА*

Ю.С. Зайцева (*julia.zaytsev@gmail.com*)

Б.Р. Андриевский (*boris.andrievsky@gmail.com*)

Институт проблем машиноведения РАН,
Санкт-Петербургский государственный университет,
Санкт-Петербург

Применение интеллектуальных методов в области мехатроники и робототехники является актуальной темой в связи с необходимостью перехода промышленности на цифровые технологии. В данной работе представлен подход к машинному обучению контура управления электромеханической системы, имеющей исполнительный приводной механизм. Система управления в режиме реального времени поддерживает заданную скорость вращения привода с помощью дискретного ПИ-регулятора, реализованного в среде MATLAB/Simulink. Задачей обучения для системы является максимизация быстродействия привода непосредственно на работающей установке, при этом параметры регулятора настраиваются автоматически. Обучение проводится с помощью симплекс-метода и алгоритма случайного поиска. Результаты экспериментов представлены в виде иллюстраций работы обоих алгоритмов.

Ключевые слова: метаэвристики, эволюционный алгоритм, вибрационные технологии, оптимизация параметров, настройка регулятора, индустрия 4.0, обучающий алгоритм.

Введение

Интеллектуальные методы управления все чаще используются совместно со стандартными регуляторами в технических системах с обратной связью. При этом эффективность работы таких систем определяется выбранным с учетом ее особенностей алгоритмом. На практике разработчики стремятся получить от алгоритма как можно большую эффективность

* Работа выполнена при финансовой поддержке Министерства науки и высшего образования РФ (проект № 075-15-2021-573).

при наименьших затратах ресурсов. В области робототехники и мехатроники каждая итерация взаимодействия со средой – затратная операция, по сравнению с которой любые вычисления на компьютере можно считать очень дешевыми. Поэтому в этих областях выгоднее использовать алгоритмы наиболее эффективные по числу итераций, либо задать среду компьютерной программой. В автономных технических системах, где набор данных неизвестен, применяют различные методы машинного обучения с подкреплением. Наиболее эффективными являются нейронные сети, алгоритмы на основе Q-обучения и метаэвристики [Zaitceva et al., 2022a]. Последний метод является универсальным, позволяет работать в условиях недоступности измерения полного вектора состояния объекта, при этом не требуется предварительная настройка, как в случае нейронных сетей.

Одними из часто встречающихся задач в мехатронике являются настройка параметров регулятора в режиме реального времени без участия человека и слежение за задающим воздействием. Простота и эффективность пропорционально-интегрально-дифференциального (ПИД)-регулятора позволяет эффективно применять его в современных промышленных процессах. Однако зависимость параметров регулятора от условий эксплуатации и неопределенностей процесса усложняет их настройку. Решить эту проблему помогают методы обучения с подкреплением [Sutton et al., 2018]. В рамках классического подхода известна работа [Fernandez-Gauna et al., 2014], в которой рассмотрена настройка ПИ-регулятора на основе Марковского процесса принятия решений для системы управления приводом подачи шарико-винтовой передачи в целях поддержания точности позиционирования. Часто, когда существует риск повреждения оборудования, проводят предварительное обучение перед взаимодействием робота в режиме реального времени, как это показано в [Dogru et al., 2022]. Для настройки регуляторов также могут быть привлечены нейронные сети, как например, в [Lawrence et al., 2022], где регулятор и среда реализованы на компьютере в виде нейронной сети актер-критик, а робот обучается дистанционно по сети Ethernet. Касательно человеко-машинных систем, в которых в контуре управления находится человек-оператор, можно выделить следующие исследования. Так, в [Guler et al., 2022] с помощью нейронной сети предложена настройка регулятора системы ручного управления сверлильного робота для нескольких разных задач, одной из функций которого является распознавание действий человека-оператора в режиме реального времени. Также человек-оператор может выступать в качестве регулятора, и тогда может потребоваться его обучение, или настройка параметров, как, например, показано в [Зайцева, 2020] с помощью эвристического алгоритма.

1. Описание электромеханической системы

Тенденция к цифровизации промышленного оборудования привела к необходимости исследования этой возможности в области машиностроения [Сиваченко, 2016]. Так, под руководством проф. А.Л. Фрадкова, в стенах лаборатории «Механобр-Техника», вибрационная машина, изображенная на рис. 1, была оснащена цифровыми блоками управления. После чего началось активное исследование по применению различных интеллектуальных методов управления и развитие новых вибрационных технологий, результаты которых отражены в работах [Фрадков и др., 2013], [Блехман и др., 2001], [Zaitceva et al., 2022b]. На данный момент имеются результаты по применению к вибрационной установке алгоритма скоростного градиента для задачи кратной частотной синхронизации [Фрадков и др., 2013] и прохождения частоты Зоммерфельда [Блехман и др., 2001], адаптивного закона управления с неявной эталонной моделью для задачи настройки параметров регулятора и слежения за заданным фазовым сдвигом между роторами [Zaitceva et al., 2022b]. В данном исследовании рассмотрен новый алгоритм управления вибрационной машиной и представлены результаты его применения.




Рис. 1. Двухроторная вибрационная машина СВ-2М

Двухроторная вибрационная установка, представляет собой существенно нелинейную сложную электромеханическую систему [Блехман и др., 2001], [Andrievsky et al., 2016]. Основой механической части системы являются пара дебалансных вибровозбудителей 1, каждый из которых состоит из трехфазного асинхронного электродвигателя переменного тока с управляемой скоростью, связанного через вал с вибровозбудителем 2, который представляет собой неуравновешенный ротор, вращающийся на валу в вер-

тикальной плоскости на корпусе установки 3. Для уменьшения передачи вибрации стола установки на опорную раму и основание под ней используются карданные валы и виброизолирующие винтовые пружины 4. Дополнительный вибрационный стол устанавливается на крепления 5.

Управление работой правого и левого электродвигателей осуществляется через силовые частотные преобразователи, подключаемые к ЭВМ через интерфейс RS-485 и линии аналогового управления. В цепи электропитания электродвигателей установлены датчики тока. Замыкания контуров систем управления электродвигателями выполняются по импульсным датчикам вращения роторов (энкодерам).

2. Постановка задачи

Рассмотрим нелинейную систему непрерывного времени, заданную уравнениями в форме Коши:

$$\begin{aligned}\dot{x}(t) &= f(x, r, u, t), \\ y(t) &= h(x, r, u, t),\end{aligned}\tag{2.1}$$

где $x \in R^n$ – вектор состояния, $u \in R^m$ – сигнал управления, $r \in R^r$ и $y \in R^r$ – вход и выход системы, $R(*)$ – время, $(*)$ -мерное евклидово пространство, f, h – непрерывные функции. Предположим, что известно только входное воздействие и измеряемый выход системы.

Исполнительный механизм реальной технической системы обычно имеет ограничения на свои тяговые усилия, которые можно описать скалярной функцией насыщения $sat_u(\cdot) : \mathbb{F} \rightarrow [-\bar{u}, \bar{u}]$, определяемой как:

$$sat_u(u) = sign(u) \min\{|u|, \bar{u}\}, \quad \bar{u} > 0.\tag{2.2}$$

Рассмотрим управление системой (2.1) с помощью стандартного ПИ-регулятора [Andrievsky et al., 2021]:

$$u(t) = K_p e(t) + K_I \int_0^t e(t) dt,\tag{2.3}$$

где $e(t)$ – рассогласование по скорости вращения роторов между входом $r(t)$ и выходом $y(t)$ системы, K_p и K_I пропорциональный и интегральный коэффициенты соответственно.

Постановка задачи: обучить систему (2.1)-(2.3) машинным методом обрабатывать заданный сигнал скорости вращения роторов с максимальным быстродействием и ограничением на перерегулирование переходного процесса.

3. Обучение с подкреплением

Концепция обучения с подкреплением предполагает наличие интеллектуальной сущности (агента), принимающей решения и взаимодействующей со средой, которая задается зависящим от времени состоянием s_t [Sutton, 2018]. Среда может быть как физической, так и виртуальной, реализованной программно. Агенту в каждый момент времени доступно некоторое наблюдение среды. После каждого взаимодействия агент получает вознаграждение r_t , оценивающее, насколько желательным было последнее действие a_t . Процесс обучения направлен на поиск стратегии, обеспечивающей максимальное вознаграждение. Одним из подходов к решению задачи обучения с подкреплением является метаэвристический, в котором не используется формализм Марковского процесса принятия решений. Метаэвристикой можно назвать следующий функционал: $J(\theta) \rightarrow \max_{\theta \in \Theta}$ со стохастическим оракулом нулевого порядка, т.е. с возможностью для каждой точки $\theta \in \Theta$ получить несмещенную оценку $J \approx J(\theta)$ [Luke, 2013].

В теории обучения с подкреплением принята гипотеза о том, что любую интеллектуальную задачу можно описать при помощи функции вознаграждения. В соответствии с постановкой задачи в данной работе выполняется машинное обучение системы, в результате которого исполнительный механизм должен обрабатывать заданный сигнал с максимальным быстродействием, т.е. количественно вознаграждение равняется минимальному времени переходного процесса. Нежелательные действия агента, которые могут привести к повреждению оборудования, обычно ограничиваются введением в алгоритм функции штрафа.

Систему управления вибрационной установкой можно условно разделить на среду и агент, как показано на рис. 2. Среда реализована в виде программы ЭВМ. ПИ-регулятор также «физически» находится на компьютере. Агентом выступает отдельно стоящая вибрационная установка, модель которой не известна, а измерению доступны только скорость вращения роторов на входе и выходе.




Рис. 2. Взаимодействие компонентов в задаче обучения с подкреплением

В общем виде задачу машинного обучения системы (2.1)-(2.3) можно записать как:

$$J(\theta) \rightarrow \max_{\theta \in \Theta} R(a_t, s_t), \quad (3.1)$$

где R – функция вознаграждения, θ – вектор параметров ПИ-регулятора (2.3), Θ – конечное множество, a_t – действие агента, s_t – соответствующее действию состояние среды, $t=1, 2 \dots M$.

В данной работе в качестве среды выступает компьютерная программа, а агентом – приводной механизм вибрационной машины, описание функции вознаграждения которого предлагается в следующем виде:

$$R(a_{t+1}, s_{t+1}) = T_s(a_{t+1}), \text{ если } T_s(a_{t+1}) < T_s(a_t), \quad (3.2)$$

где T_s – время переходного процесса.

Функцию штрафа можно описать любым числом, значительно большим, чем T_s , например, как:

$$P(a_{t+1}, s_{t+1}) = \begin{cases} 1000, \text{ если } \sigma(a_{t+1}) > \sigma^*, \\ 1000, \text{ если } K_p \cap K_t < 0, \end{cases} \quad (3.3)$$

где σ^* и σ – заданное и фактическое перерегулирование переходного процесса соответственно. Ограничение перерегулирования обосновано целями безопасности и исключения ударных режимов работы машины.

Для решения задачи (3.1) используются два алгоритма безградиентного поиска: симплекс-метод [Nelder et al., 1965] и алгоритм на основе случайного поиска [Растрингин, 1969]. Далее представлен псевдокод для каждого алгоритма.

3.1. Алгоритм обучения агента на основе симплекс-метода

Симплекс-метод широко известен и удобен тем, что реализован стандартно в функциях языков программирования Python, MATLAB и др. Алгоритм заключается в формировании симплекса и последующего его деформирования в направлении минимума, посредством операций отражения, растяжения и сжатия. В данной работе алгоритм минимизирует функцию качества (3.1), начиная из точки равной начальным параметрам ПИ-регулятора (2.3). Ниже представлен псевдокод алгоритма вычисления функции качества (3.1), в котором процедура поиска экстремума на основе симплекс-метода обозначена стандартной функцией MATLAB *fminsearch*.

Алгоритм 1.

Вход: заданная скорость вращения роторов r , ограничение управляющего сигнала \underline{u} , вектор начальных параметров регулятора K_0 , перерегулирование по скорости σ^* , время моделирования T_{sim} , счетчик итераций N , величина функции штрафа P .

Выход: минимальное время переходного процесса T_s .

- 1 Процедура *Procedure1*
 - 2 метка:
 - 3 $fminsearch(K_0)$;
 - 4 $N++$
 - 5 Проверка положительности параметров регулятора: если $K_0 < 0$, тогда $R:=P$;
 - 6 перейти на метку;
 - 7 По измеренным на выходе скоростям вращения роторов вычислить время переходного процесса и величину перерегулирования σ для каждого ротора;
 - 8 если $\sigma > \sigma^*$ тогда $R:=P$;
 - 9 перейти на метку;
 - 10 Вычислить среднее арифметическое время переходного процесса T_s между двумя роторами;
 - 11 $R := T_s$;
 - 12 если $R < P$ тогда $P:=R$
 - 13 перейти на метку
 - 14 конец
-

Стандартные функции удобны в применении и сокращают время исследования, однако имеют свои недостатки и отсутствие возможности изменения кода в лучшую сторону. Несмотря на хорошие результаты в различных областях применения, алгоритм не имеет теории сходимости, а успех в достижении экстремума зависит от характера решаемой проблемы и начальных параметров.

3.2. Алгоритм обучения агента на основе случайного поиска

Несмотря на существование различных модификаций алгоритмов на основе случайного поиска, все они имеют шаги, состоящие в выборе точек и направлений в области изменения независимых переменных из нормального распределения. В рамках задач управления техникой, инжене-

рам приходится заранее оценивать область, в которой выбираются случайные точки, что скорее всего приведет поиск к удовлетворительному результату. Ниже описан алгоритм вычисления процедуры, который может заменить функцию *fminsearch* в *Алгоритме 1*.

Алгоритм 2.

Вход: величина шага S , случайный вектор $\xi^{1 \times 4}$, коэффициент дисконтирования γ , номер итерации i .

Выход: минимальное время переходного процесса T_s .

- 1 Процедура *Procedure2*
 - 2 Пока не будет достигнуто терминальное условие, выполнять:
 - 3 если $N > 6$ тогда $K := K_0 + S * \xi - \gamma$,
 - 4 иначе $K := K_0 + S * \xi$;
 - 5 если $T_s < R$ тогда $K_0 := K$
 - 6 $R := T_s$;
 - 7 иначе $i ++$;
 - 8 если $i := 15$ тогда $i := 0$,
 - 9 $S := S/2$,
 - 10 $\gamma := \gamma/2$;
 - 11 конец
-

В качестве терминального условия целесообразно выбрать количество итераций. В *Алгоритме 2* регулируются величина шага и коэффициент дисконтирования в зависимости от количества итераций, настроенных на рассматриваемую задачу. Вектор ξ в данном случае содержит четыре коэффициента регулятора – по два для каждого ротора.

4. Результаты экспериментов

Ниже представлены иллюстрации работы описанных выше алгоритмов после проведения экспериментов на двухроторной вибрационной машине. Для обоих алгоритмов начальные параметры регулятора (2.3) выбраны следующими: $K_{op} = 450$ с/рад и $K_{op} = 300$ 1/рад. Параметры системы приняты: $\omega = 60$ рад/с, $\omega_0 = 40$ рад/с, $\sigma^* = 0.4$, $T_{sim} = 10$ с, $S = 50$, $\gamma = 1$. На рис. 3 показано как итерационно меняется функция награды (3.2). Результаты показывают, что при использовании алгоритма случайного поиска минимум функции награды составляет 1.8 с, симплекс-метод дает результат приблизительно в два раза больше (3.57 с).




Рис. 3. Процесс поиска минимума функции вознаграждения

Рассмотрим результаты экспериментов работы алгоритма случайного поиска более подробно. На рис. 4 показано, как меняются коэффициенты регулятора в процессе настройки. В точке минимума коэффициенты регулятора для левого ротора равны: $K_P=636$ с/рад и $K_I=313$ 1/рад, для правого ротора – $K_P=512$ с/рад и $K_I=225$ 1/рад. Для этих значений выполнены пуски вибрационной машины для серии заданных скоростей, равных 40, 60, 80 рад/с. Результаты показаны на рис. 5.

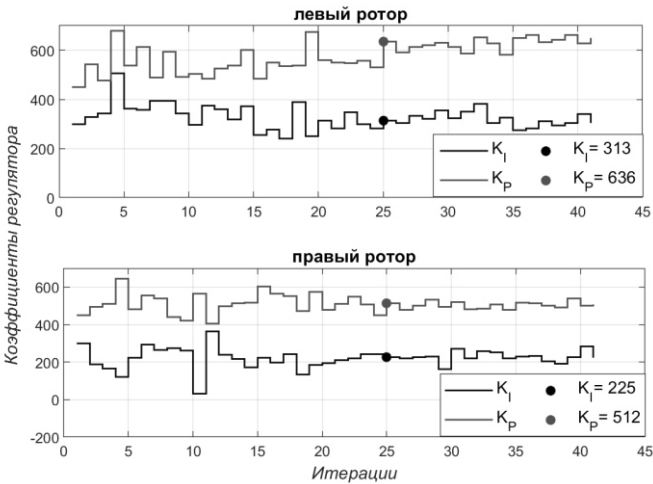


Рис. 4. Процесс настройки коэффициентов регулятора согласно Алгоритму 2

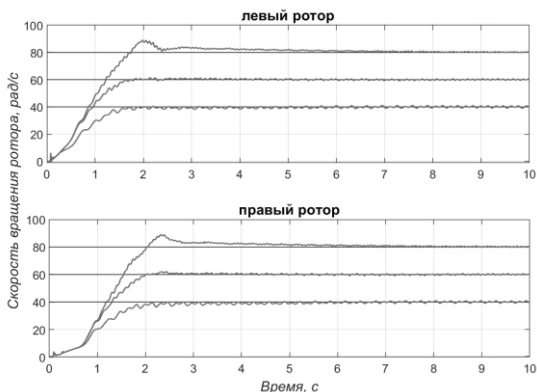


Рис. 5. Заданная и фактическая скорость вращения роторов при коэффициентах регулятора, соответствующих минимуму функции вознаграждения

Заключение

В работе представлен подход к обучению регулятора системы управления скоростью вращения роторов вибрационной машины. В процессе обучения параметры регулятора машины настраиваются с помощью симплекс-метода и алгоритма на основе случайного поиска. Работоспособность предложенного подхода проверена экспериментально, а результаты представлены иллюстрациями. Алгоритм на основе случайного поиска показал более высокую эффективность, по сравнению с симплекс-методом, выражающуюся в возможности настроить регулятор так, что машина обрабатывает заданную скорость в два раза быстрее.

Список литературы

- [Блехман, 2001] Управление мехатронными вибрационными установками / под ред. Блехмана И.И., Фрадкова А.Л. – СПб.: Наука, 2001.
- [Зайцева, 2020] Зайцева Ю.С. Настройка параметров динамической модели пилота в контуре управления летательным аппаратом // Научно-технический вестник ИТМО. – 2020. – № 20 (2). – <https://doi.org/10.17586/2226-1494-2020-20-2-200-205>.
- [Растргин, 1969] Теория и применение случайного поиска. – Рига: Зинатне, 1969.
- [Сиваченко, 2016] Сиваченко Л.А., Сиваченко Т.Л. Технологическое машиностроение как основа передовых промышленных технологий // Вестник Белорусско-Российского университета. – 2016. – № 4(53).
- [Фрадков, 2013] Фрадков А.Л., Томчина О.П., Галицкая В.А., Горлатов Д.В. Интегро-дифференцирующие алгоритмы скоростного градиента в задачах кратчайшей синхронизации вибрационных установок // Научно-технический вестник ИТМО. – 2013. – № 1 (83). – URL: <https://ntv.ifmo.ru/file/article/4047.pdf>.

- [**Andrievsky, 2016**] Andrievsky B., Boikov V., Fradkov A., Seifullaev R. Mechatronic Laboratory Setup for Study of Controlled Nonlinear Vibrations // IFAC-PapersOnLine. – 2016. – Vol.49. – <https://doi.org/10.1016/j.ifacol.2016.07.963>.
- [**Dogru, 2022**] Dogru O., Velswamy K., Ibrahim F. Reinforcement learning approach to autonomous PID tuning // Computers & Chemical Engineering. – 2022. – Vol. 161. – P. 107760. – <https://doi.org/10.1016/j.compchemeng.2022.107760>.
- [**Fernandez-Gauna, 2014**] Fernandez-Gauna B., Ansoategui I., Etxeberria-Agiriano I., Graa M. Reinforcement learning of ball screw feed drive controllers // Engineering Applications of Artificial Intelligence. – 2014. – Vol. 30. – <https://doi.org/10.1016/j.engappai.2014.01.015>.
- [**Guler, 2022**] Guler B., Niaz P.P., Madani A. An adaptive admittance controller for collaborative drilling with a robot based on subtask classification via deep learning // Mechatronics. – 2022. – Vol. 86.
- [**Lawrence, 2022**] Lawrence N.P., Forbes M.G., Loewen P.D., McClement D.G., Backstrom J., Gopaluni R.B. Deep reinforcement learning with shallow controllers: An experimental application to PID tuning // Control Engineering Practice. – 2022. – Vol. 121. – <https://doi.org/10.106/j.conengprac.2021.105046>.
- [**Luke, 2013**] Luke S. Essentials of Metaheuristics. – 2nd ed. – Lulu Raleigh. 2013.
- [**Nelder, 1965**] Nelder J.A., Mead R. A Simplex Method for Function Minimization // The Computer Journal. – 1965. – Vol. 7, No. 4. – <https://doi.org/10.1093/comjnl/7.4.308>.
- [**Sutton, 2018**] Sutton R.S., Barto A.G. Reinforcement Learning: An Introduction. Second edition. – Cambridge, MA: The MIT Press. 2018.
- [**Zaitceva, 2022a**] Zaitceva I., Andrievsky B. Methods of Intelligent Control in Mechatronics and Robotic Engineering: a Survey // Electronics. – 2022. – Vol. 11 (5), 2443. – <https://doi.org/10.3390/electronics11152443>.
- [**Zaitceva, 2022b**] Zaitceva I.S., Andrievsky B.R. Adaptive multiple synchronization and rotors phase shift tracking for two-rotor vibration machine // Materials Physics and Mechanics. – 2022. – Vol. 50 (2).

ИНДУСТРИЯ 5.0: ОСНОВЫ СОЗДАНИЯ НЕЙРО-ЦИФРОВОГО ИНТЕЛЛЕКТА НА ПРИМЕРЕ КОМПАНИИ SPACEX

А.В. Колесников (*a.kolesnikov@yandex.ru*)

С.И. Корягин (*skoryagin@kantiana.ru*)

И.В. Либерман (*iliberman@kantiana.ru*)

П.М. Клачек (*pklachek@mail.ru*)

БФУ имени И. Канта, г. Калининград

А.В. Бабкин (*al-vas@mail.ru*)

Санкт-Петербургский политехнический университет

Петра Великого, г. Санкт-Петербург

Рассмотрены основные особенности интегрированной модели глобальной трансформации общества на основе движения к нообществу и нейросфере, которая может стать базисом для создания кибер-социальных экосистем Индустрии 5.0. Предложена модель нейро-цифрового интеллекта инструментария стратегического целеполагания и планирования Индустрии 5.0, представляющая особый вид конвергенции кибер мира коллективного интеллекта с физическим миром промышленных операционных технологий Индустрии 5.0. Представлена прикладная модель экосистемой трансформации компании SpaceX и разработанная на ее основе модель когнитивного производства компании SpaceX на основе нейро-цифрового интеллекта, а также результаты их внедрения в рамках проекта Starship компании SpaceX.

Ключевые слова: цифровая трансформация, когнитивное производство, искусственный интеллект, киберсоциальная система, Индустрия 5.0, нейросфера.

Введение

В [Ташенова и др., 2021] впервые в мировой научной практике представлены специфические особенности функционирования киберсоциальных экосистем Индустрии 5.0 и шесть вспомогательных технологий, играющих важную роль в процессе перехода, на основе конвергенции опе-

рационных и информационных технологий, производств на новый технологический уклад. Эти исследования согласуются с результатами компании IBM [Vonnaud и др., 2020], а также с [Бабкин и др., 2021, Федоров и др., 2021, Квинт и др., 2021] по эволюции Индустрии 4.0 и когнитивного производства.

В [Клейнер и др., 2018], представлен фундаментальный, системно-целевой базисный комплекс особенностей киберсоциальных экосистем Индустрии 5.0: гомеостаз, локализованность в пространстве и непрерывность (неограниченность) существования во времени; структурный изоморфизм и т.д. Исследование системно-целевого базиса Г.Б. Клейнера, на основе теории стратегирования [Квинт и др., 2020], ноономики [Бодрунов и др., 2018], методологии и технологии решения сложных задач методами функциональных гибридных интеллектуальных систем [Колесников и др., 2007], позволили сформулировать интегрированную модель глобальной трансформации общества к нообществу и нейросфере [Бабкин и др., 2021 (3)], а также разработать прикладной нейро-цифровой подход и инструментарий стратегического целеполагания и планирования проектирования киберсоциальных экосистем Индустрии 5.0, подробно изложенной в [Бабкин и др., 2022].

В [Бабкин и др., 2021 (2)] предложено понятие Индустрии 5.0 как киберсоциальной системы – совокупности взаимодействующих системно-целевых акторов-экосистем, функционирующих и самоорганизующихся в "Нейросфере", формируемой коллективным человеко-машинным интеллектом. Здесь же рассмотрена и нейро-экосистемная модель концепции Индустрия 5.0 – основы нейро-цифрового инструментария стратегического целеполагания и планирования, гармонично объединяющего технологи Индустрии 4.0 и человеко-ориентированным подход Индустрии 5.0 в рамках концепции Брента Кедзерски с коллективным интеллектом в рамках концепции объединения человеческого и машинного интеллекта Оздчан Саритас. Как показали исследования [Бабкин и др., 2022] нейро-цифровой инструментарий позволяет реализовать различные прикладные варианты киберсоциальных экосистем Индустрии 5.0. Практическая реализация на основе данного инструментария тестового варианта киберсоциальной экосистемы «глобального архитектурного мышления Индустрии 5.0» в рамках проекта Starship компании SpaceX [Бабкин и др., 2022], продемонстрировала высокую эффективность и большой научно-теоретический и прикладной потенциал.

Цель данного исследования – дальнейшее развитие нейро-цифрового инструментария стратегического целеполагания и планирования, на основе модели нейро-цифрового интеллекта, как особого вида конвергенции кибер мира коллективного интеллекта с физическим миром промышленных операционных технологий.

1. Методологические основы создания нейро-цифрового интеллекта прикладных инструментариев Индустрии 5.0.

Совместные работы авторов статьи в области гибридного вычислительного интеллекта [Клачек и др., 2020], и научной школы профессора А.В. Колесникова в области методологии и технологии решения сложных задач методами функциональных гибридных интеллектуальных систем [Колесников и др., 2007], привели к созданию модели синергетической исследовательской среды [Klachek и др., 2019], объединяющей возможности знаинтенсивных технологий Индустрии 4.0 с человеко-ориентированным подходом Индустрии 5.0, на основе эволюционной модели коллективного интеллекта [Бабкин и др., 2021 (2)]. Развитие модели синергетической исследовательской среды, на основе теории стратегирования [Квинт и др., 2021] и нономики [Бодрунов и др., 2018], а также системно-целевой методологии и технологии создания нейро-цифровых экосистем [Федоров и др., 2021 (1)], позволили авторам сформулировать методологическую триаду нейро-цифрового инструментария стратегического целеполагания и планирования Индустрии 5.0 [Бабкин и др., 2021 (2)].

Методологическая триада нейро-цифрового инструментария стратегического целеполагания и планирования Индустрии 5.0., включает понятия задачи-системы, когнитивного фрейма и интеллектуальных маркеров [Бабкин и др., 2021 (2)]. Развивая, предлагаемое академиком РАН В.Л. Квинтом и профессором С.Д. Бодруновым фундаментальное понимание целеполагания, миссии видения, целей и задач стратегии как формализовано самостоятельные и при этом взаимосвязанные и взаимодополняющие основные элементы (документы) стратегии, сформулированы базовые положения и понятия, активно развиваемой в настоящее время, универсальной нейро-цифровой парадигмы проектирования нейро-цифрового инструментария стратегического целеполагания и планирования [Бабкин и др., 2022]. В её лежит принцип стратегирования мышления, основанный на современных нейрофизиологических теориях и положениях об иерархическом принципе интеграции скоростных, медленных и сверхмедленных информационно-управляющих систем головного мозга, формируемых для обеспечения когнитивных состояний и познавательной деятельности человека, включая вербальную ассоциативно-мыслительную активность. Центральное понятие принципа стратегирования мышления – «когнитивная гиперциклическая самоорганизация». Когнитивный гиперцикл, представляющий взаимосвязанную совокупность моделей вычислений задачи-системы, реализуется на основе системно-целевой интеграции и согласованной самоорганизации нейро-цифровой системы [Бабкин и др., 2022] естественного и искусственного интеллекта.

Прикладные исследования авторов, в частности по проекту Starship компании SpaceX, показали, что основная проблема нейро-цифровых инструментов стратегического целеполагания и планирования Индустрии 5.0., с которой столкнулись, в том числе и в компании SpaceX, связана с возможностью реализации особого вида конвергенции кибер мира коллективного интеллекта с физическим миром промышленных операционных технологий. Для решения данной проблемы, на основе системно-целевой методологии и технологии создания нейро-цифровых экосистем [Федоров и др., 2021 (2)], в рамках данного исследования, авторами предложена модель нейро-цифрового интеллекта, и прикладной инструментальной создания когнитивного производства Индустрии 5.0.

2. Модель нейро-цифрового интеллекта инструментария стратегического целеполагания и планирования Индустрии 5.0

Центральный элемент модели нейро-цифрового интеллекта (рис. 1) основан на понятии генезиса когнитивных вычислений [Бабкин и др., 2021 (2)]. Когнитивный гиперцикл как взаимосвязанная совокупность моделей когнитивных вычислений, реализуется системно-целевой интеграцией и согласованной самоорганизацией нейро-цифровой интеллекта – результата конвергенции кибер мира человеческого и искусственного интеллекта. В результате генезиса когнитивных вычислений, как основы для создания различных моделей коллективного интеллекта, происходит сопряжение мыслительной структуры человека с мыслительной структурой искусственного интеллекта и формирование нелинейных когнитивных связей с уникальными синергетическими свойствами и поддающихся формальному описанию и реализации посредством супер искусственного интеллекта, на основе компьютерной модели мозга человека. Таким образом реализуется система-образующая процедура $\dot{m}_7 \uparrow$ генезиса знаний, в соответствии, с которой формируется переход нейро-цифровой системы в процессе когнитивных вычислений, как результат многошагового синтеза целей и в конечном итоге формирования окончательной структуры системно-целевой модели стратегируемого объекта. Сопряжение мыслительной структуры человека с мыслительной структурой искусственного интеллекта, в процессе которых синтезируется модель когнитивного фрейма стратегируемого объекта на основе когнитивных вычислительных процедур $\dot{m}_1 - \dot{m}_6$ (рис. 1), происходит на основе био-кибернетической системы нейрофизиологического мышления, в том числе на основе 5D виртуального погружения, посредством различных видов стимуляции мышления и нервной системы человека. Основная идея заключается в возможности интеграции, на основе применения мета когнитивного визионариума,

быстрый в производстве массовый носитель. Для этого, необходимо создать принципиально новое когнитивное реиндустриализованное производство и промышленность высоких и прорывных технологий. Это требует разработки и применения методов и инструментариев активных индустриальных стратегий реинжиниринга и стратегического планирования, позволяющих «работать над максимальным сближением компонент производственного нооиндустриального процесса, сокращать путь от знания к продукту, имплементируя знания и в продукт, и в навыки, и в компетенции, создавая путем интеграции производства, науки и образования индустриальные комплексы, субъекты индустриального сектора нового типа, которые заменят в будущем нынешние производства традиционного типа» [Квинт и др., 2021].

В [Бабкин и др., 2021 (3)] представлены основы экосистемой трансформации промышленных систем на основе нейро-цифрового инструментария. В рамках данного подхода разработана модель экосистемой трансформации компании SpaseX [Бабкин и др., 2022] – основы модели когнитивного производства компании SpaseX на основе нейро-цифрового интеллекта (рис. 2).

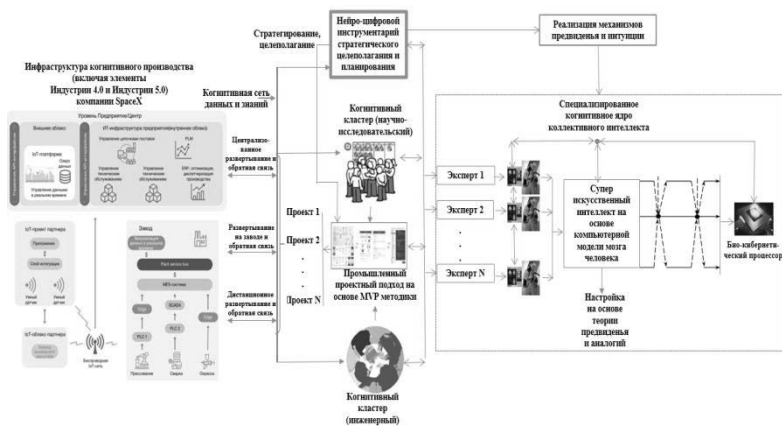


Рис. 2. Модель когнитивного производства компании SpaseX на основе нейро-цифрового интеллекта

Представленная на рис. 2 модель реализует мета системную интеграцию: нейро-экосистемной модели концепции Индустрия 5.0 [Федоров и др., 2021 (1)]; модели взаимосвязи процессов предвидения, прогнозирования, стратегирования и планирования [Квинт и др., 2021]; модели нового индустриального общества второго поколения [Квинт и др., 2021.]

Эта модель позволяет: 1) Сформировать перспективные системы управления развитием производств и предприятий, компании SpaceX в рамках концепции Индустрии 5.0., адаптированные к условиям нейро-цифровой реиндустриализации и трансформации, отличающихся учетом полисубъектности и многоуровневого характера управления развитием на основе знаниеинтенсивных технологий; 2) Обеспечить возможность формирования принципиально новых типов инновационного комплекса стратегированных экосистем, как системы взаимосвязанных агентов для создания, хранения и передачи знаний, умений, трансфера новых знаниеинтенсивных технологий [Квинт и др., 2021]; 3) Заложить возможность широко-масштабного применения неистощенных природных ресур созданием принципиально новых подходов и инструментариев изменения соотношения материало- и знаниеемкости в конечном продукте [Квинт и др., 2021].

Как показали предварительные результаты исследования, внедрение упрощенной версии кибер социальной системы глобального архитектурного мышления [Бабкин и др., 2022], на основе применения модели когнитивного производства компании SpaceX, существенно повышает эффективность когнитивного производства, в том числе в рамках проекта Starship/Super Heavy. Например, производительность технических функций может быть увеличена за короткий промежуток времени более чем на 50 %, обеспечивая: прирост продуктивности, повышение пропускной способности и эффективности, исключение бесполезной деятельности, предотвращение отказов, избежание переделок, брака, отказов, продукции низкого качества и т.д.

Заключение

Пятнадцать лет назад в [Макаров и др., 2007] член-корреспондент РАН Г. Б. Клейнер, по мнению авторов, представил, идеальную формулировку понятия стратегии Индустрии 5.0: «В условиях расширения и развития экономики знаний успех стратегии будет достигаться лишь тогда, когда создателю стратегии удастся настроить свою душу в резонанс с "душой" предприятия, свои мысли – с обобщённым "мозгом" предприятия, а свои ощущения – с сигналами внешней социально-экономической среды. Вот почему каждая эффективная (в некотором смысле правильная) стратегия должна содержать результат открытия, озарения, а не только применения готовых моделей, правил и процедур». В работе профессора А.В. Колесникова представлена авторская парадигма двунаправленной гибридизации «Гибридизация ... состоит в совместном применении различных методов и (или) моделей для обработки информации об одном и том же объекте. Парадигма такого подхода основана на согласии с тем, что любая сколь угодно сложная искусственная модель реального объекта всегда будет

примитивнее и проще оригинала, и только многоаспектное его изучение с последующей интеграцией получаемых результатов позволит обрести необходимые знания или приблизиться к оптимальному решению» [Колесников и др., 2007], развитие которой на основе нейро-цифрового подхода и прикладных инструментариев привело к созданию основ нейро-цифрового интеллекта. Авторы надеются, что решенные ими методологические задачи исследования и разработанный прикладной вариант модели нейро-цифрового интеллекта, позволят реализовать пророческие мысли Г.Б. Клейнера, и создать тестовый вариант «резонатора Г.Б. Клейнера и А.В. Колесникова, в виде нейро-цифрового интеллекта Индустрии 5.0». Также авторы надеются, что прикладное внедрение создаваемого ими «резонатора Г. Б. Клейнера и А. В. Колесникова» в виде кибер социальной системы "глобального архитектурного мышления" компании SpaceX, станет важным элементом в проекте Starship, и поможет Человечеству решить его главную задачу – стать межпланетным видом.

Данная статья продолжает цикл авторских исследований и научных статей, посвященных созданию концепции Индустрия 5.0, являясь следующим шагом в объединении усилий авторов концепций стратегирования (В.Л. Квинт), ноономики (С.Д. Бодрунов), системной парадигмы и системной экономики (Г.Б. Клейнер), методологии и технологии решения сложных задач методами функциональных гибридных интеллектуальных систем (А.В. Колесников) и других авторских работ в области цифровой экономики, гибридного вычислительного интеллекта и мета системных технологий. Идея объединения взглядов авторов на проблемы создания концепции Индустрия 5.0 остаются неизменными и имеют целью создать общую научную платформу обеспечивающую: развитие теории и методологии стратегирования на основе мета системных подходов в области концепции Индустрия 5.0; создание новой концепции развития высокотехнологичной промышленности Индустрия 5.0 на основе гибридного вычислительного и нейро-цифрового интеллекта; создание методологии и прикладных инструментариев построения новых типов социально-экономических, киберсоциальных, нейро-цифровых экосистем, и т.д., – являясь темами, предполагаемого цикла, последующих научных статей

Список литературы

[Ташенова и др., 2021] Ташенова Л.В., Бабкин А.В. Индустрия 5.0 и киберсоциальные экосистемы: сущность и особенности // Индустрия 5.0, цифровая экономика и интеллектуальные экосистемы (ЭКОПРОМ-2021): сборник трудов Всероссийской (Национальной) научно-практической конференции, 18–20 ноября 2021 г. / Под ред. д-ра экон. наук, проф. Д. Г. Родионова, д-ра экон. наук, проф. А.В. Бапкина. – СПб.: ПОЛИТЕХ-ПРЕСС, 2021. – С. 200-205. – Doi: 10.18720/IEP/2021.3/55.

- [**Bonnaud и др., 2020**] Bonnaud S., Didier C. Industrie 4.0 & Fabrication Cognitive. Cas d'usage, Patterns d'Architecture, Solutions IBM. – URL: <https://www.ibm.com/downloads/cas/N8DLLD6A> (дата обращения: 18.05.2020).
- [**Бабкин и др., 2021 (1)**] Бабкин А.В., Шкарулета Е.В., Плотников В.А. Интеллектуальная киберсоциальная экосистема Индустрии 5.0: понятие, сущность, модель // *Экономическое возрождение России*. – 2021. – № 4 (70). – С. 39-62. – Doi: 10.37930/1990-9780-2021-4-70-39-62.
- [**Федоров и др., 2021 (1)**] Федоров А.А. и др. Технология проектирования нейродиффральных экосистем для реализации концепции Индустрия 5.0 // *Научно-технические ведомости СПбГПУ. Экономические науки*. – 2021. – Т. 14, № 3. – С. 19-39. – Doi: 10.18721/ЖЕ.14302.
- [**Квинт и др., 2021**] Квинт В.Л., Бодрунов С.Д. Стратегирование трансформации общества: знание, технологии, ноономика: монография. – СПб.: ИНИР им. С.Ю. Витте, 2021. – 351 с.
- [**Клейнер и др., 2018**] Клейнер Г.Б. Социально-экономические экосистемы в свете системной парадигмы // *Системный анализ в экономике* – 2018: Сборник трудов V Международной научно-практической конференции / под общ. ред. Г.Б. Клейнера, С.Е. Щепетовой. – М.: Прометей, 2018. – С. 5-14.
- [**Квинт и др., 2020**] Квинт В.Л. Концепция стратегирования: монография. Т. 2. – СПб.: СЗИУ РАНХиГС, 2020. – 164 с.
- [**Бодрунов и др., 2018**] Бодрунов С.Д. Ноономика: монография. – М.: Культурная революция, 2018. – 432 с. – ISBN 978-5-6040343-1-6.
- [**Колесников и др., 2007**] Колесников А.В., Кириков И.А. Методология и технология решения сложных задач методами функциональных гибридных интеллектуальных систем. – М.: ИПИ РАН, 2007. – 387 с., ил. – ISBN 978-5-902030-55-3.
- [**Федоров и др., 2021 (2)**] Федоров А.А., Корягин С.И., Либерман И.В., Клачек П.М., Полупан К.Л. Основы создания нейро-цифровых экосистем. Гибридный вычислительный интеллект: монография. – Калининград: Изд-во БФУ им. И. Канта, 2021. – 320 с.
- [**Бабкин и др., 2021 (2)**] Бабкин А.В., Федоров А.А., Либерман И.В., Клачек П.М. Индустрия 5.0: понятие, формирование и развитие. Экономика промышленности // *Russian Journal of Industrial Economics*. – 2021. – 14 (4). – С. 375-395. – <https://doi.org/10.17073/2072-1633-2021-4-375-395>.
- [**Klachek и др., 2019**] Klachek P., Polypan K., Liberman I. Development of a synergetic research environment for modeling complex productive and economic systems. // *Int. Rev. St. Petersburg State Polytechnical University Journal. Economics*. – 2019. – Vol. 12, No. 2. – P. 112-117. – Doi: 10.18721/ЖЕ.12211.
- [**Бабкин и др., 2022**] Бабкин А.В., Корягин С.И., Либерман И.В., Клачек П.М., Богданова А.А., Сагателян Н.Х. Индустрия 5.0: Нейро-цифровой инструментарий стратегического целеполагания и планирования // *Технико-технологические проблемы сервиса*. – 2022. – № 3 (61). – С. 64-85.
- [**Клачек и др., 2020**] Клачек П.М., Полупан К.Л., Корягин С.И., Либерман И.В. Гибридный вычислительный интеллект. Основы теории и технологий создания прикладных систем: монография. – 2-е изд., дополненное. – Калининград: Изд-во БФУ им. И. Канта, 2020. – 340 с.

- [Клачек и др., 2019]** Клачек П.М., Полупан К.Л., Либерман И.В. Цифровизация экономики на основе системно-целевой технологии управления знаниями // Научно-технические ведомости СПбГПУ. Экономические науки. – 2019. – Т. 12, № 3. – С. 9-19. – Doi: 10.18721/Е.12301.
- [Бабкин и др., 2021 (3)]** Бабкин А.В., Федоров А.А., Либерман И.В., Клачек П.М. Индустрия 5.0: инструментарий стратегического целеполагания и планирования // Индустрия 5.0, цифровая экономика и интеллектуальные экосистемы (ЭКОПРОМ-2021): Сборник трудов Всероссийской (Национальной) научно-практической конференции, 18–20 ноября 2021 г. / под ред. д-ра экон. наук, проф. Д. Г. Родионова, д-ра экон. наук, проф. А. В. Бабкина. – СПб. : ПОЛИТЕХ-ПРЕСС, 2021. – С. 25-32. – Doi: 10.18720/IEP/2021.3/2.
- [Макаров и др., 2007]** Макаров В.Л., Клейнер Г.Б. Микроэкономика знаний: монография. – М.: ЗАО Издательство "Экономика", 2007. – С. 204. – <https://doi.org/10.32609/0042-8736-2007-9-152-154>.

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПО ТЕХНИЧЕСКОМУ ОБЕСПЕЧЕНИЮ ФЛОТА

А.В. Колесников (*a.kolesnikov@yandex.ru*)

БФУ имени И. Канта, г. Калининград

Э.И. Мухитов (*mukh70@yandex.ru*)

Управление Балтийского флота, г. Калининград

Обоснование актуальности поддержки принятия решений по техническому обеспечению сил флота. Рассматривается концептуальная модель иерархии системы управления техническим обеспечением флота, а также трансформация неструктурированной информации в структурированные данные. Приведены концептуальная модель логистической информационно-интеллектуальной системы для поддержки принятия решений по техническому обеспечению флота и требования к ее аппаратно-программному облику, результаты онтологического моделирования и декомпозиция проблем управления.

Ключевые слова: техническое обеспечение военной деятельности, система поддержки принятия решений, логистическая информационно-интеллектуальная система.

Введение

Как и в любой другой сфере человеческой деятельности, связанной с умственным трудом, принятием управленческих решений, техническое обеспечение (ТехО) войск – область, где актуальна автоматизация обработки неструктурированной информации. Огромные объемы информации, начиная от данных, поступающих с датчиков, сенсоров, контроллеров вооружения и военной техники, а также видео- и фотоматериалы, сводки и донесения, даже военно-политическая обстановка, – всё это очень сложно структурировать. Для подготовки и принятия качественного управленческого решения для лиц, формирующих решения (ЛФР), и лиц, принимающих решения (ЛПР) и ещё для автоматизации этого процесса, тот должен быть вербализован и формализован. Штабы и пункты управления ТехО переходят от табелей срочных донесений к электронным

стандартизированным формам, которые структурированы уже и без лишней обработки их можно использовать как основу для систем подготовки принятия решений (СППР), замыслов и планов ТехО в виде графических и директивных документов. Однако, существует порядка 80% информации, которую невозможно подвергнуть машинной обработке. С субъективной точки зрения – из-за критериев и ограничений, объективно – из-за отсутствия теоретических положений и законченных исследований. Уровень развития компьютеров и систем искусственного интеллекта (СИИ) уже сейчас позволяет разрабатывать СППР для каждой предметной области, включая техническое обеспечение флота, при этом требуется решение задач, которые «помогут» ЛПР выработать и принять рациональное управленческое решение.

1. Особенности моделирования и интеллектуального управления техническим обеспечением флота

Системе управления техническим обеспечением флота присущи свойства сложных (больших) систем [Колесников, 2001а]. Так, например, концептуальная модель её иерархии (рис.1) включает уровни: планирования (организации), координации (адаптации) и регулирования (исполнительный уровень).

Точками обозначены инфокоммуникационные узлы пирамиды управления флотом, сплошными линиями – горизонтальные жесткие связи взаимодополняемых, взаимозаменяемых пунктов управления (для дублирования, устойчивости и робастности) системы. Штриховые линии – вертикальные связи уровней управления. Серым цветом выделены уровни актуальности автоматизированной выработки и выбора управленческих решений с точки зрения учета неопределенностей и точности (верификации) управленческих решений и выполнимости задач нижестоящим исполнителем уровнем.

Уровень планирования представлен командованием флота (верхняя точка пирамиды обозначает командующего, ниже – его заместители, организаторы ТехО). На уровне координации так обозначены органы военного управления – управления, отделы и службы – каждый по своей направленности, своей предметной области и круга ведения. Координируют работу системы ТехО флота в соответствии с нормативно-правовыми актами и планами, утвержденными на верхнем уровне иерархии и коррелируют с нижестоящими звеньями системы.

На верхних уровнях управления актуальны для автоматизации: задачи распознавания, прогнозирования и предикативного анализа развития ситуации, а решения направлены на адаптацию и устойчивую работу системы управления ТехО независимо от различного рода возмущений.

Уровень регулирования составляет командование объединений, соединений сил флота (верхний исполнительный уровень), также по своей специализации, по каждому виду ТехО: автотехническому, электромеханическому, инженерно-техническому, метрологическому и т.д. Уровень объектов управления (нижний исполнительный уровень) включает воинские части и корабли флота.

Геометрический образ «пирамиды» демонстрирует то обстоятельство, что чем ниже уровень управления, тем меньший объем знаний требуется для выработки и выбора решений, и, наоборот, чем выше уровень, тем больше когнитивных усилий требуется решателям, нарастает неопределенность и, следовательно, релевантность решений.




Рис. 1. Концептуальная модель иерархии системы управления техническим обеспечением флота

Концепция интеллектуальных систем управления [Макаров, 2001], в которых при формировании управляющих воздействий используются механизмы обработки знаний, организованные с привлечением средств современных информационных технологий, помогающих субъекту «узнать», «понять», «запомнить», «оценить ситуацию», «найти решение» и «проверить исполнение», воплощается для сферы тылового и технического обеспечения Вооруженных Сил как логистическая информационно-интеллектуальная система (ЛИИС).

Применение классической процедуры синтеза управляющего устройства [Бабула и др., 2021a] в практике военной деятельности серьезно затруднено. Точная математическая модель объекта управления, как сово-

купность обеспечивающих и обеспечиваемых сил, с учетом множества параметров внутренней и окружающей систему ТехО среды, часто слишком сложна или неизвестна. Изменения окружающей среды воздействуют на объект управления различного рода возмущениями – дополнительным источником неопределенности его характеристик. Если объект относится к сложным динамическим системам, то выбор алгоритма адаптации резко усложняется, трудно подобрать оптимальные значения параметров устройства адаптации, существующие же методики анализа и синтеза адаптивных информационных систем управления чрезмерно упрощают задачи.

В этой связи концепция интеллектуальных систем управления предполагает отказ от необходимости получения точной математической модели объекта, переход к использованию знаний ЛПР, а также методов и технологий искусственного интеллекта.

2. Трансформация неструктурированной информации в структурированные данные в системах поддержки принятия решений по техническому обеспечению флота

Для качественной трансформации неструктурированной информации современной наукой применяются различные методы: обработка больших объемов информации (ресурсов) в предметной области (онтологий); автоматизация создания и поддержки решений на основе машинного обучения и статистических подходов; гибридизация для улучшения качества релевантно поступающей неструктурированной информации и структурирования данных.

Если спроецировать внедрение этих методов на военную сферу, то существенных результатов тут достигло Агентство перспективных исследовательских проектов Министерства обороны США DARPA. В нашей стране системами искусственного интеллекта военного назначения занимаются ведущие научно-исследовательские организации и известные ученые: В.И. Городецкий, А.П. Еремеев, А.А. Зацаринный, А.В. Колесников, Э.А. Трахтенгерц, И.Б. Фоминых, Н.Г. Ярушкина, и др. Широта охвата и применения тематики ИИ крайне обширна – от космических аппаратов до микробиологии.

Для сферы тылового и технического обеспечения Вооруженных Сил актуальна разработка и внедрение логистических информационно-интеллектуальных систем (ЛИИС) с учётом того, что задачи обеспечения, эшелонирования, складирования, транспортировки и другие схожи и взаимодополняемы - и в гражданском, и в военном секторах. Специальное программное обеспечение и СИИ гражданского назначения должно быть интероперабельно и интегрировано как по вертикали, так и по горизонтали управления видами и родами Вооруженных Сил. Это позволит постро-

ить сетевую архитектуру всех видов обеспечения – на принципах и правилах логистики. Гражданский сектор более насыщен современными логистическими технологиями логико-семантических, логико-вероятностных и логико-математических средств извлечения знаний из неструктурированной информации и превращающими эти знания в полноценные управленческие решения [Шамаев и др., 2021]. Военный сектор вполне может адаптировать и применять эти технологии в своих целях. Это позволяет классифицировать перспективные ЛИИС, как гибридные синергетические интеллектуальные системы с открытой архитектурой [Колесников, 2001b], [Чуваков, 2015].

На рис. 2 представлена концептуальная модель логистической информационно-интеллектуальной системы технического обеспечения флота, на вход которой поступает неструктурированная информация, после чего оператор (ЛФР) осуществляет ее фильтрацию, сепарирование, первоначальное структурирование и заполнение внутренней базы данных о зависимых объектах и подчиненных силах, и внешняя БД о независимых объектах, обеспечиваемых силами, противнике, гидрометеословиях и другое.

Рис. 2. Концептуальная модель логистической информационно-интеллектуальной системы технического обеспечения флота

Переработка поступающей неструктурированной информации в структурированные данные, их передача и использование в интеллектуальном блоке, алгоритмизует процессы поддержки принятия решений и обработки специальным программным обеспечением (СПО). В результате ЛИИС способна не только распознавать образы, но и создавать основу смысло-

вого, семантического распознавания информации, которая в последующем позволит моделировать действия обеспечивающих и обеспечиваемых сил и подразделений ТехО [Быстров, 2018]. Чем больше будет разработано, просчитано и проверено на практике (учения, тренировки, боевые действия) таких моделей, тем база знаний будет релевантнее предметной области. Таким образом, в ЛИИС информационная единица компьютерной обработки данных – структурированные данные в БД информационно-справочного блока, а знания поступят в БЗ интеллектуального блока [Демихов и др., 2020].

ЛИИС на этапе разработки обучается: распознаванию образов (буквы, цифры, знаки), пониманию смысла этих образов, и уже из них создает абзацы, предложения (например, по видам ТехО), встраивает их в пункты и рубрики формализованного управленческого решения, заданного ЛФР, представляет математически просчитанные в расчетно-логистическом блоке альтернативы решений с учетом информационных потребностей и удобства восприятия пользователей, в первую очередь, ЛПР. В процессе эксплуатации ЛПР через экранно-картографический блок из трех-пяти альтернатив замысла или решения, предлагаемой ЛИИС, пользователь может выбрать управленческое решение, которое рационально с точки зрения его интуиции, опыта и профессиональных знаний.

Интеллектуальный блок ЛИИС обладает следующими признаками: непрерывный контроль и слежение за выполнением цели управления и ее коррекция, что приближает систему ТехО к процессу интеллектуального «понимания» ее предназначения; подчиненность друг другу задач регулирования планирования тактических действий и выбора стратегии поведения в зависимости от складывающейся релевантной обстановки; расширение информационных каналов и усложнение задач классификации по результатам контроля состояния как объекта, так и внешней среды, влияющей на мотивацию цели и выбор программы действий системы; использование при решении трудно формализуемых задач интеллектуального типа процедур манипуляции со знаниями, учитывающих ограничения на располагаемые ресурсы.

Экспертная подсистема интеллектуального блока воплощает знание-ориентированный подход, в котором источники наполнения БЗ – эксперты-аналитики и представительские тексты, описывающие предметную область «Техническое обеспечение флота». Переработка неструктурированной информации, ее структурирование выполняются методами и алгоритмами нейросетевой подсистемы.

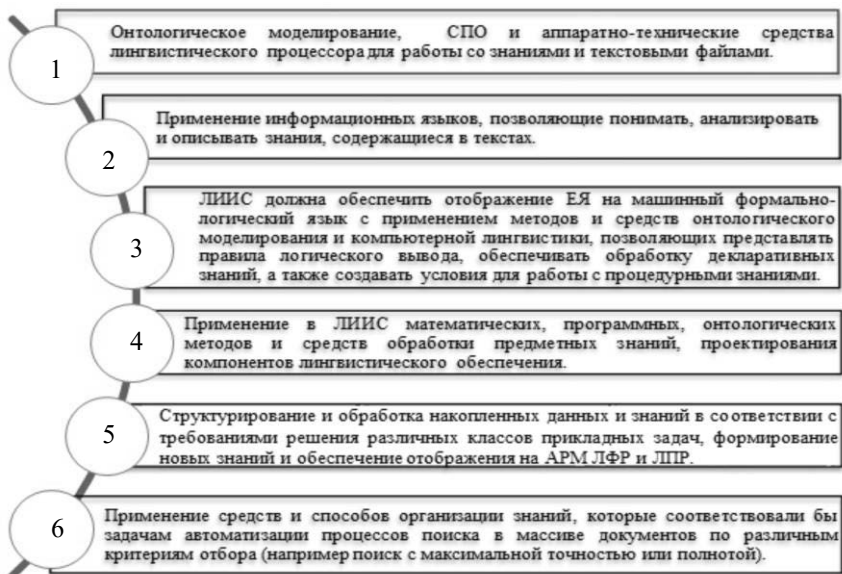


Рис. 3. Требования к аппаратно-техническому облику логистической информационно-интеллектуальной системы поддержки принятия управленческих решений по техническому обеспечению флота

Консультативные альтернативы для принятия ЛПР решений вырабатываются гибридным моделированием в интеллектуальном блоке [Колесников, 2007]. Это позволяет устанавливать отношения между образами, понятиями, осуществлять синтез знаний, их интероперабельность и выявлять семантическую близость. Декларативные знания поступают в ЛИИС в процессе онтологического моделирования предметной области по видам технического обеспечения флота. Для их представления используются известные методы [Рыбина, 2018]. Знания в ЛИИС понимаются как результат продуктивного осмысления фактов (декларативной информации) о предметной области «Техническое обеспечение флота» и преобразование ее с помощью правил (процедур) в управленческие решения. Интегрированные знания представляются в знание-ориентированном подходе и являются компонентами онтологии предметной области. Выявление подобных знаний осуществляется с помощью онтологического моделирования предметной области «Техническое обеспечение флота» средствами компьютерной лингвистики и специального программного обеспечения [Михайловский, 2015].

На основе рассмотренной выше концептуальной модели выработаны требования к аппаратно-техническому облику логистической информационно-интеллектуальной системы поддержки принятия управленческих решений по техническому обеспечению флота (рис. 3). Шесть групп требований изображены как единое целое, формирующее и обуславливающее аппаратно-технический облик ЛИИС.

3. Онтологическое моделирование и декомпозиция проблем управления техническим обеспечением флота

Онтологическое моделирование (см. рис.3) «выстраивает» онтологические отношения пользователей (ЛФР, ЛПР) и машинного компонента управления знаниями ЛИИС – основы систем семантического анализа текстовой информации.

Нейросетевая подсистема воплощает в себе регламентированные процедуры и семантический анализ, во-первых, на этапе сбора, извлечения знаний из входящей в ЛИИС информации с формализацией в виде логико-семантических структур. Во-вторых, эта система на этапе подготовки решения осуществляет хранение в БЗ, обработку и манипулирование знаниями и данными в процессе решения каждой подзадачи ТехО для включения их в состав графической и директивной части управленческого решения. Формализация – процесс трансформации знаний, представленных в текстах, в знания-аналоги БЗ для решения задач ЛИИС, связанных с хранением, семантическим поиском и извлечением нужных знаний для каждой подзадачи управленческого решения [Бавула и др., 2021]. Немаловажную роль в БЗ играют размещенные здесь факты и правила логического вывода, полученные в результате применения методов онтологического моделирования и компьютерной лингвистики.

Ниже представлена декомпозиция проблем технического обеспечения флота, сущность и пути их решения (инструментарий), применяемые в логистической информационно-интеллектуальной системе:

- проблема повышения эффективности управления, заключающаяся в разрешении противоречий между возможностями органа военного управления и способностью ЛПР реализовать их в ходе решения задач по предназначению в соответствии с требованиями вышестоящих органов военного управления и сложившимися условиями обстановки;
- проблема оперативности управления, заключающаяся в разрешении противоречий между требуемым и располагаемым временем решения задачи пунктами управления ТехО (применяются матмоделирование, статистические методы);

- проблема качества управленческих решений, заключающаяся во-первых, в разрешении противоречий между возможностями пунктов управления по выработке управленческого решения и возможностями сил ТехО по выполнению задач по предназначению (применяется теория принятия решений, системный анализ, теория массового обслуживания, теория игр, имитационное моделирование), а во-вторых в разрешении противоречий между оптимальной реализацией возможностей сил и средств ТехО и способностью органов военного управления формировать управленческие решения, обеспечить цели управления (применяются теория игр, теория графов, метод «Монте-Карло», экспертные системы, алгоритм нечеткого вывода Мамдани);
- проблема автоматизации управления, заключающаяся в разрешении противоречий между возможностями ЛПП и требованиями по объему, скорости и качеству обработки информации (применяются теория управления, теория принятия решений, теория мультиагентных систем, язык моделирования GPSS);
- проблема методологии, заключающаяся в разрешении противоречий между методами, моделями, формами, способами управления и практической работой операторов (ЛФР) пунктов управлений (применяются логистическое и имитационное моделирование, методы виртуальной реальности).

Представленная выше декомпозиция – основа для применения проблемно-структурной методологии решения проблем планирования и координации технического обеспечения флота методами и технологиями гибридных интеллектуальных систем [Колесников, 2001с].

Результатом знание-ориентированного подхода при использовании ЛИИС будет «прохождение» информации через информационно-справочный блок, «насыщение» релевантными данными через СУБД, структурирование в соответствии с формализованными пунктами решения (физико-географические условия, уровень технической исправности вооружения и военной техники, уровень обеспечения материально-техническими средствами и пр.) и автоматизированный выбор из базы знаний СУБЗ 3-5 наиболее подходящих по семантико-лингвистическим параметрам альтернатив решений. Эти альтернативы также онтологически классифицированы по задачам флота в мирный или угрожаемый период, при переводе флота в высшие степени готовности, при ведении боевых действий или операций. Интеллектуальный блок предоставляет ЛПП альтернативы, которые в процессе подготовки принятия решения, происходит их корректировка, пересчет математических показателей и вывод на мониторы экранно-картографического блока готовых управленческих решений в виде приказов, директив, планов технического обеспечения. Не-

маловажной функцией ЛИИС является проверка качества управленческих решений с помощью программных средств имитационного моделирования. Таким образом все виды технического обеспечения коррелируются между собой, вся система будет работать более согласованно и робастно.

Заключение

Разработанная концептуальная модель иерархии «пирамиды» управления флотом позволяет сделать вывод о целесообразности применения концепции интеллектуальных систем управления И.М. Макарова и В.М. Лохина с привлечением средств современных информационных технологий, помогающих субъекту управления «узнать», «понять», «запомнить», «оценить ситуацию», «найти решение» и «проверить исполнение» – для автоматизированного решения проблемных ситуаций.

Трансформация неструктурированной информации в структурированные данные в системах поддержки принятия решений по техническому обеспечению флота рассматривается весьма удобной в контексте концептуальной модели логистической информационно-интеллектуальной системы технического обеспечения флота для пользования – с точки зрения поиска и выработки альтернатив управленческих решений не только путем простого семантического ввода и поиска ключевых слов и словосочетаний, но и учитывая смысловое содержание обрабатываемой неструктурированной информации формализованных электронных таблиц срочных донесений, широко используемых в военной сфере.

Выработанные требования, рассмотренные как единое целое, формируют облик логистической информационно-интеллектуальной системы поддержки принятия решений по техническому обеспечению флота. Результаты онтологического моделирования позволили «построить» онтологические отношения пользователей и машинного компонента управления знаниями ЛИИС – основы систем семантического анализа текстовой информации, а также выстроить декомпозицию проблем технического обеспечения – основы для применения проблемно-структурной методологии разрешения решения проблемных ситуаций планирования и координации методами и технологиями гибридных интеллектуальных систем.

Список литературы

- [Бавула и др., 2021] Бавула А.А., Мухитов Э.И. Теоретические основы интеллектуально-логистической поддержки решений в управлении системой технического обеспечения флота. Монография. Филиал ФГКВОУВО ВУНЦ ВМФ «Военно-морская академия» в г. Калининграде. – 2021. – 235 с.
- [Быстров, 2018] Быстров И.И., Козичев В.Н., Ширманов А.В. и др. Автоматизированная обработка неструктурированной информации в перспективных автоматизированных системах военного назначения: концептуальные основы // Военная мысль. – 2018. – № 8.

- [Демихов и др., 2020] Демихов Е.Н., Малинин М.В., Новиков В.А. и др. Предложения по совершенствованию программного обеспечения АСУ организационно-технических систем специального назначения за счет внедрения системы поддержки принятия решения // Известия РАН. – 2020. – № 2.
- [Колесников, 2007] Колесников А.В., Кириков И.А. Методология и технология решения сложных задач методами функциональных гибридных интеллектуальных систем. – М.: ИПИ РАН, 2007. – 387 с.
- [Колесников, 2001] Колесников А.В. Гибридные интеллектуальные системы. Теория и технология разработки / под ред. А.М. Яшина. – СПб.: Изд-во СПбГТУ, 2001.
- [Макаров, 2001] Макаров И.М. и др. Интеллектуальные системы автоматического управления / под ред. И.М. Макарова, В.М. Лохина. – М.: Физматлит, 2001.
- [Михайловский, 2015] Михайловский, А.Б., Сайфетдинов Х.И. Оперативные основы создания перспективного облика системы управления Вооруженными Силами Российской Федерации // Военная мысль. – 2015. – № 11.
- [Рыбина, 2018] Рыбина Г.В. Особенности приобретения, представления и обработки темпоральных знаний для автоматизированного построения баз знаний в динамических интегрированных экспертных системах // Материалы IV Всероссийской Поспеловской конференции «Гибридные и синергетические интеллектуальные системы». – Калининград: Изд-во БФУ им. И. Канта, 2018.
- [Чуваков, 2015] Чуваков А.В. Разработка информационных систем подготовки принятия решений при управлении сложными техническими системами / Международный научный журнал «Символ науки» – 2015 – №6.
- [Шамаев и др., 2021] Шамаев С.М., Воробьева П.С., Миргалеев А.Т., Толстов Г.С. и др. Применение технологии распределенного реестра (блокчейн) для создания автоматизированных систем управления материальными ресурсами на этапах производства и эксплуатации вооружения, военной и специальной техники // Вооружение и экономика. – 2021. – № 2 (56).

СЕМИОТИЧЕСКАЯ МОДЕЛЬ МЕНТАЛЬНОГО ПРОСТРАНСТВА

А.А. Кулинич (*kulinich@ipu.ru*)

Институт проблем управления РАН, Москва

В качестве модели поддержки принятия решений предлагается рассматривать качественную модель ментального пространства человека. В отличие от двухпроцессной модели Д. Канемана в модели ментального пространства представляется образ решаемой проблемы (репрезентация), в терминах опыта человека и различные механизмы манипуляции элементами образа с привлечением наличных знаний, знаний приобретаемых в сети Интернет, что позволяет перестраивать начальную репрезентацию до репрезентации решения. В этом случае поддержка принятия решений направлена не на борьбу с когнитивными искажениями, а на поддержку структурных характеристик ментального пространства, которые обеспечивают высокую интеллектуальную продуктивность лица, принимающего решение.

Ключевые слова: прикладная семиотика, поддержка принятия решений, ментальное пространство, построитель ментального пространства, обработка естественного языка.

Введение

В теории принятия решений выделяют три способа принятия решений: рациональный; основанный на суждениях; интуитивный. Рациональный метод принятия решений предполагает наличие полной информации о параметрах объекта принятия решений. Этот метод характеризуется наличием строгого алгоритма принятия решений, который в обобщенном виде, заключается в последовательном выполнении этапов: выявления проблемы (цели); определение критериев принятия решений; определение веса каждого критерия (предпочтение эксперта); определение альтернатив принятия решений; оценка альтернатив по всем критериям с учетом их веса; выбор лучшей альтернативы. Результатом выполнения всех этих этапов является упорядоченные согласно оценкам альтернативы, естественно, что лучшая альтернатива имеет максимальную оценку. Лицу, при-

нимающему ответственные решения, предлагается принять именно эту альтернативу как решение выделенной проблемы. Однако гарантий, что выбрано лучшее решение этот рациональный метод не даст.

Дело заключается в субъективности при выполнении ряда этапов этого метода. Так при выделении проблемы, определении критериев, их веса, альтернатив эксперт опирается на личный опыт, и поэтому могут присутствовать ошибки, связанные с природой человеческого оценивания и мышления. Такие ошибки называются когнитивными искажениями, а поведение человека при принятии решений в этом случае определяют термин «ограниченная рациональность» [Саймон, 1993].

В рамках многочисленных исследований когнитивных искажений выделяются и систематизируются их виды, предложены модели интеллекта, объясняющие разного рода когнитивные искажения [Канеман, и др., 2005].

Для уменьшения влияния когнитивных искажений изменяют алгоритм рационального метода принятия решений с применением различных методов поддержки разных этапов этого метода [Kahneman, et al., 2019]. При этом считается, что интуиция, включаемая в процесс принятия решений, позволяет избавиться от множества когнитивных искажений.

В случаях, когда трудно сформулировать проблему (цели), критерии и альтернативы применяют направленный поиск этих параметров с применением метода SWOT, позволяющий акцентировать внимание лица принимающего решения на сильных качествах и потенциальных возможностях решения анализируемой проблемы, а не стремиться исправить все угрозы и слабости. Для выявления основных причин возникновения проблемы применяют метод диаграммы Парето, позволяющий определить очередность устранения причин. На выявление причин возникшей проблемы направлена так называемая схема Исикава [Исикава, 1988], представляющая причины в виде иерархической схемы.

Для генерации альтернатив применяются подходы интуитивного поиска. Это методы: гирлянд ассоциаций и аналогий, морфологического ящика, мозгового штурма, синектика. Интуитивные методы основаны на использовании ментального опыта, не требуют обоснования и анализа ситуации, поэтому принимаются очень оперативно, однако содержат разного рода когнитивные искажения, снижающие эффективность решений. В принятии решений находят применение так называемые интеллект карты (ментальные карты, карты памяти и др.). Это технология, предложенная психологом Т. Бьюзенем [Бьюзен, 2021], направлена на структуризацию и визуализацию знаний эксперта о решаемой проблеме. Считается, что визуализация знаний в виде разнообразных диаграмм способствует генерации новых креативных решений.

Несмотря на субъективность интуитивных решений и большой риск получения ошибочного решения, рациональные и интуитивные решения дополняют друг друга [Разваляева, 2021]. Роль интуитивных решений повышается в условиях принятия решений в системах, параметры которых изменяются случайно с неизвестными характеристиками. Однако, считается, что интуитивное решение должно быть строго обосновано, логическим или экспериментальным способом, что не всегда возможно.

В области поведенческой экономики предложена двухпроцессная психологическая модель принятия решений. Эта психологическая модель состоит из двух систем. Первая система позволяет решать несложные проблемы, как правило, на основе эвристик и шаблонов принятия решений, которые представляются как опыт лица принимающего решение. Решения этой системы не требуют обдумывания и поэтому принимаются быстро. Вторая система – медленная система, требует перед принятием решений обдумывания [Канеман, 2005]. Эта модель достаточна абстрактна и не представляет механизмы принятия решений в интеллекте человека, не поднимает вопросы организации опыта человека, его знаний, восприятие действительности и ее представление в интеллекте человека.

Учитывая многообразие подходов принятия решений возникает вопрос о возможности применения того или иного подхода для принятия решений в ситуациях разной сложности и о качестве принятого решения. Считается, что в сложных плохо определенных ситуациях, в условиях ограниченной рациональности говорить об оптимальности принятого решения не приходится. В этом случае вводится понятие ограниченной оптимальности [Zilberstein, 1998], которое можно связать с компромиссом лица принимающего решение относительно качества решения и затратами на его получение. Принято выделять три градации такого компромисса [Misuraca, et al., 2015]: максимизация, сатисфизация, минимизация. Максимизация – это стремление эксперта найти лучший вариант, даже если это требует значительных затрат времени и других ресурсов. Сатисфизация предполагает поиск варианта решения, который соответствует определенному порогу приемлемости для человека. Минимизация – это стремление минимизировать количество ресурсов для получения возможного решения.

В сложных быстро меняющихся ситуациях возможные варианты поведения лица принимающего решения – это сатисфизация и минимизация. В этом случае в качестве модели поддержки принятия решений предлагается рассматривать качественную модель ментального пространства человека. В отличие от двухпроцессной модели Д. Канемана в модели ментального пространства представляется образ решаемой проблемы (репрезентация), в терминах опыта человека и различные механизмы манипуля-

ции элементами образа с привлечением наличных знаний позволяет перестраивать начальную репрезентацию до репрезентации решения. В этом случае поддержка принятия решений направлена не на борьбу с когнитивными искажениями, а на поддержку структурных характеристик ментального пространства, которые обеспечивают высокую интеллектуальную продуктивность лица, принимающего решение. Рассмотрим психологические исследования организации ментальных пространств, и их характеристики, отвечающие за интеллектуальную продуктивность человека

1. Ментальное пространство

Ментальное пространство (*mental space*) – это динамическая форма ментального опыта, которая актуализуется в условиях познавательного взаимодействия субъекта с миром [Холодная, 2002].

Понятие «ментального пространства» ввел Г. Фоконье для объяснения гибкости языковых средств при порождении необычных словосочетаний и метафор [Fausonnier, 1994]. Ментальные пространства рассматривались как области, используемые для порождения и объединения информации.

Понятие ментальных пространств получило свое развитие в рамках «теории концептуальной интеграции» (*conceptual blending theory*), разработанной в работе [Fausonnier, Turner, 1998]. Здесь авторы рассмотрели процесс конструирования новых идей. Авторы считают, что для образования ментального пространства используются построители ментального пространства. В их понимании – это обычные слова, которые образуются связи с понятиями предметной области, т.е. строится концептуальная среда для мышления. В работе [Lakoff, 1987] ментальное пространство определяется как среда концептуализации и мышления.

Величковский Б. М. использовал понятие ментального пространства для объяснения эффектов переработки информации на уровне высших символических функций. Эксперименты показали, что единицы представления ментального пространства могут быть развернуты в полноценный ментальный пространственный контекст в зависимости от поставленной задачи (например, от образа дома можно мысленно перейти к образу района города, в котором этот дом располагается) [Величковский, 2006]. В качестве элементов ментального пространства рассматриваются психические образования – когнитивные структуры - прототипы, понятия, фреймы, сценарии, когнитивные карты, принимающие участие в переработке и хранении информации. [Величковский, 2006]. Устройство и структуру ментального пространства Б.М. Величковский видит как множество рекурсивно вложенных ментальных пространств, организация которых обеспечивает возможность любых вариантов движения мысли, вплоть до контрфактических и абсурдных идей.

В работе [Холодная, 2002] ментальное пространство определяется как динамическая форма ментального опыта. При этом сам ментальный опыт функционально неоднороден и состоит из трех взаимодействующих слоев опыта: когнитивного; метакогнитивного; интенционального.

Метакогнитивный опыт отвечает за познавательный стиль лица, принимающего решение. Интенциональный опыт отражает способности эксперта при формулировке цели, личных предпочтений и оценок. Когнитивный опыт обеспечивает контакт с реальностью и кодирование информации. Когнитивный опыт связывают с концептуальным пространством (понятийной системой) человека, от организации которой в значительной степени зависит его интеллектуальные способности.

При отображении действительности реальность в ментальном пространстве представляется в виде множества понятий, связанных родовыми отношениями. Исследованию характеристик концептуального пространства интеллекта посвящены многочисленные работы психологов, пытающихся связать уровень интеллекта со структурными характеристиками его концептуальной системы.

Интеллектуальные способности субъекта связывают со степенью сложности концептуальной системы, включающей множество понятий, отражающих реальный мир. Высокая степень сложности когнитивной системы означает, что субъект создает многомерную модель реальности, выделяя в ней множество взаимосвязанных сторон. Низкая степень сложности, напротив, свидетельствует о том, что понимание и интерпретация действительности происходящего осуществляется в упрощенной форме на основе ограниченного набора субъективных измерений. Когнитивная сложность (степени дифференцированности понятий (конструктов)) отражает число понятий, с помощью которых субъект описывает наблюдаемую действительность.

В работе [Schroder et al. 1970] сложность субъективного пространства предлагается оценивать не только на основе показателя когнитивной сложности (степени дифференцированности понятий), но и на основе характера их взаимосвязанности (степень интегрированности конструктов). Еще одной важной структурной характеристикой концептуальной системы считается ее «конкретность-абстрактность». «Конкретная» концептуальная система характеризуется незначительной дифференциацией и интеграцией, имеющихся у субъекта понятий. Субъект с такой концептуальной системой склонен к «черно-белому» восприятию действительности, зависит от авторитетов, внешних обстоятельств. «Абстрактная» понятийная система, напротив, имеет высокие показатели дифференциации и интеграции наличных понятий. Для субъекта с абстрактной понятийной системой характерна независимость, гибкость и т.д.

Исследования Э. Рош [Rosch, 1978] показали существование в иерархической структуре понятийной системы особого уровня иерархии. Это так называемый базовый уровень. На базовом уровне расположены базовые понятия, которые играют особую роль в мышлении субъекта. Базовые понятия – это понятия, которые обычно находятся на среднем уровне иерархии концептуального пространства (иерархии «общее-частное»). Они отличаются тем, что связаны с мыслительным и подсознательным опытом субъекта гораздо теснее, чем другие понятия.

Среди механизмов модификации понятий выделяются: обобщение, ограничение понятий, а также механизм модификации понятия с помощью связки признак – значение признака. Обобщение и ограничение понятия представляется, в зависимости от способа определения понятия, путем отбрасывания или добавления признака. Модификация понятия с помощью связки признак - значение признака основывается на существовании зависимости между значениями признаков понятия с его определением. Изменение значений признаков или их состава в процессе развития наблюдаемой действительности или в результате мысленных операций с понятиями и их признаками приводит к изменениям в концептуальном пространстве. Таким образом, концептуальная система работает «по принципу «калейдоскопа», так как обладает способностью перетряхивать в самых различных комбинациях элементы наличной семантики в направлении выделения семантических инвариантов» [Холодная, 2002]. Принцип модификации понятия с помощью отношения признак - значение признака рассматривался в работах Квиллиана об организации семантической памяти субъекта [Quillian, 1968].

Дж. Лакофф считает, что ментальное пространство субъекта структурируют когнитивные модели [Lakoff, 1987]. При этом когнитивная модель включает две обязательные компоненты: понятия базового уровня и образно-схематические концепты. Дж. Лакофф выделил основные типы идеализированных когнитивных моделей (ИКМ), каждая из которых задает шаблоны для построения разного рода ментальных моделей: пространства; онтологий предметных областей; отношений разного рода между понятиями базового уровня и т.д.

В работе [Gardenfors, 2000] ментальное пространство интерпретируется как концептуальное пространство, в котором понятие (*concept*) представляется как n -мерное концептуальное (ментальное) векторное пространство, оси которого представляются как качественные признаки (вес, температура, цвет и т.д.) и их значения. Каждый конкретный объект рассматривается как точка в этом пространстве, а координаты этой точки определяют меру выраженности соответствующих качественных признаков. При этом сходство двух объектов определяется как расстояние между точками, представляющие эти объекты.

Выше приведенный краткий обзор исследований психологов о ментальных пространствах не является исчерпывающим. При построении математической модели ментального пространства важно выделить основные базовые принципы организации и функционирования ментальных пространств в процессах принятия решений. Поэтому, обобщая исследования когнитивных психологов структуры и механизмов работы ментального пространства можно сделать следующие выводы:

1. Ментальное пространство – это среда концептуализации и мышления [Lakoff, 1987];

2. Познавательный контакт с реальным миром обеспечивает когнитивный опыт ментального пространства [Холодная, 2002]. Элементами представления реального мира в когнитивном опыте являются: знаки, понятия, фреймы, сценарии, онтологии и др.

3. Концептуальные структуры включают множество понятийных кластеров, имеющих иерархическую структуру понятий, связанных родовидовыми отношениями, множество признаков и механизмы модификации понятия в рамках родовидовой иерархии.

4. В иерархической организации концептуальной системы выделяются понятия базового уровня, которые находятся на среднем уровне иерархии и связаны с мыслительным и подсознательным опытом субъекта гораздо теснее, чем другие понятия.

5. Концептуальные структуры характеризуются показателями: дифференцированности-интегрированности, характеризующий число понятий и число связей между ними; абстрактности-конкретности учитывающий связи между абстрактными и конкретными понятиями; концептуальной сложности, учитывающий развитость механизмов кодирования и модификации понятий. Структурные характеристики индивидуальной понятийной системы отражают интеллектуальные способности субъекта. На характеристики концептуальной системы можно влиять с помощью систем поддержки принятия решений, повышая уровень информированности лица принимающего решения.

6. Модификация понятий в концептуальной системе связана с отношением признак-значение признака. Это означает, что изменение значения признаков понятия, приводит к превращению одного понятия в родственное понятие, абстрактное или конкретное, принадлежащее той же или другой концептуальной системе.

7. Концептуальная система обладает свойством рекурсивности (вложенности). Свойство рекурсивности (вложенности) ментального пространства определяет принцип организации объема(ов) понятий, включенных в концептуальную систему. Рекурсивность концептуальной системы обеспечивает возможность мысленного перемещения в ментальном пространстве [Величковский, 2006].

8. Ментальные пространства включают механизмы оценивания, сравнения, предпочтений и др., которые образуют интенциональный опыт субъекта.

2. Математическая модель ментального пространства

Согласно когнитивным психологам ментальное пространство структурируется когнитивными моделями. Когнитивные модели – это, по сути, шаблоны, состоящие из базовых понятий предметной области и отношений между ними. Эти две составляющие задают шаблон, структурирующий ментальное пространство, в котором разворачивается образ решаемой задачи. Например, если субъект решает задачу прогноза развития ситуации, то шаблонами могут служить абстрактные модели динамики – системы конечно разностных, логико-лингвистические уравнения, рассуждения «Если, То» и т.д., или если решается логическая задача, то шаблонами могут быть модели логики высказываний, первого порядка и т.д. Естественно, элементами этого шаблона являются понятия базового уровня, конкретизирующие, решаемую задачу.

Познавательный контакт с действительностью обеспечивает когнитивный опыт человека. Ответственными за этот контакт являются схемы кодирования реальности для представления ее в ментальном пространстве. Связь ментальной сферы с реальностью может быть обеспечена с помощью модели знака, предложенной Г. Фреге. В модели знака три элемента: имя – обозначает объект реального мира; смысл – определяет объект реального мира (например, определяет свойства позволяющие отличить его от других объектов); значение – это и есть сам объект (денотат). При этом считается, что имя, кроме того, что обозначает объект реального мира, но и выражает его смысл. Такая структура, связывающая ментальные сущности – имя и смысл с реальным объектом – значением называется треугольником Фреге.

Системы, состоящие из множества, знаков называются семиотическими системами и исследуются в рамках метанауки – семиотики. Классики семиотики Ч. Пирс [Пирс, 2009] и Ч Моррис [Моррис, 2001] определили три аспекта семиотических систем: синтактику – определяет отношения, которыми знаки связаны в семиотической системе; семантику – определяет, что выражает семиотическая система; прагматику – определяет, как семиотическую систему воспринимает другой субъект.

В прикладной семиотике [Поспелов и др. 1999] модель семиотической системы известна как квадрат Поспелова. Квадрат Поспелова включает: метазнак, определяющий имя семиотической системы, синтаксис, определяющий правила построения знаковой системы; семантику, определяющую смысл, основные свойства семиотической системы; прагматику, определяющую основные действия, которые возможно выполнить в рамках этой семиотической системы.

В качестве модели, структурирующие ментальное пространство мы будем рассматривать семиотическую модель, включающую три, связанные параметрами модели; синтаксическую; семантическую; прагматическую [Кулинич, 2018].

Синтаксическая модель предназначена для структуризации наблюдаемой ситуации. Для этого используются шаблоны:

1. Определена предметная область $DF = \langle D, F \rangle$, где D – множество понятий и F – множество параметров предметной области.
2. Определено имя моделируемой ситуации (объекта) – $d \in D$ в предметной области DF .
3. Для ситуации с этим именем определено множество имен параметров $F^* = \{f_i\}$, $F^* \subset F$, $i = 1, \dots, N$.
4. Для каждого параметра задано множество значений, $Z = \{Z_i\}$ в виде упорядоченного множества лингвистических значений, т.е. $Z_i = \{z_{i1}, \dots, z_{iq}\}$, $z_{iq+1} \succ z_{iq}$, $q = 0 \dots n-1$.
5. Вектор параметров ситуации в момент времени t , $Z(t) = (z_{1t}, \dots, z_{nt})$ называется ее состоянием. Это состояние в начальный момент времени определяется именем d , $Z(0) \Leftrightarrow d$.
6. Определены причинно-следственные отношения W , заданные на множествах значений параметров. Динамика изменения состояния представлено как отображение:

$$W: Z(t) \rightarrow Z(t+1), \quad (1)$$

где $Z(t) \in Z_i \times Z_i$.

То есть, синтаксическая модель определена кортежем:

$$\langle F, Z, W, Z(t) \rangle, \quad (2)$$

где F – множество параметров, Z – множество множеств значений параметров, W – причинно-следственное отношение на множестве значений параметров, $Z(t)$ – вектор значений всех параметров.

Семантическая модель основана на представлении пространства возможных состояний динамической системы (1) $SS = \times_i Z_i$ как признакового семантического пространства (*Semantic Space*). Такие семантические пространства в работе [Gardenfors, 2000] определяются как концептуальные пространства. В концептуальном пространстве состояния ситуации (объекта) $Z(t)$ представляются как понятия, которые определяются именами и векторами значений признаков, определяющие их содержание (смысл). В концептуальных пространствах ситуации с близкими значениями пара-

метров образуют классы состояний, а между классами определяются отношения (класс-подкласс или род-вид), т.е. определяется концептуальная структура.

В работе [Величковский, 2006] ментальные пространства представляются как рекурсивно вложенные пространства. В работе [Кулинич, 2014] был предложен метод структуризации пространства состояний SS динамической системы (1) на вложенные области возможных состояний $SS(d^H) \subset SS$, имеющие имена d^H , $SS(d^H) \Leftrightarrow d^H$, и определяющие класс состояний системы (1).

На рис. 1-6 дана иллюстрация предложенного метода структуризации пространства состояний. На рис. 1 показан пример концептуального пространства, для объекта v , имеющего два признака $F = \{f_1, f_2\}$, значения которых определяются из множеств значений (Z_1, Z_2) , начальное состояние объекта $Z(0) = (z_{1r}, z_{2p})$, показано как точка с координатами (z_{1r}, z_{2p}) , в концептуальном пространстве $SS = Z_1 \times Z_2$.

Задана окрестность точки, представляющей начальное состояние $Z(0) = (z_1 \pm \varepsilon_1, z_2 \pm \varepsilon_2)$, где $z_i \pm \varepsilon_i \in Z_i$, $i = 1, 2$. Окрестность $z_i \pm \varepsilon_i$ значений i -го признака состояния $Z(0)$ называется интервалом толерантности класса по этому признаку $\Delta_i = [z_{ik} + \varepsilon_{ik}, z_{ik} - \varepsilon_{ik}]$. Область концептуального пространства $SS(d^0) \subset SS$, полученная прямым произведением интервалов толерантности всех признаков состояния $Z(0)$ определяет область базового понятия: $SS(d^0) = \Delta_1 \times \Delta_2$, $SS(d^0) \subset S$. Имя базового понятия совпадает с именем начального состояния, т.е. $d = d^0$, $d^0 \Leftrightarrow SS(d^0)$ (рис. 2).




Рис. 1.
Концептуальное пространство




Рис. 2. Базовое понятие




Рис. 3.
Положительное обобщение

На рис. 3 показано качественное положительное обобщение базового понятия d^0 по признаку 1. Получаем новый класс состояний динамической системы (1) с новым именем d^1 . Это новое понятие определяется в семантическом пространстве как область $SS(d^1) \subset SS$:

$$SS(d^1) = \Delta_2 \times [Z_{1q}; Z_{1n}], SS(d^1) \subset SS.$$

В эту область $SS(d^1)$ вложена область базового понятия $SS(d^0)$, т.е. $SS(d^0) \subset SS(d^1)$.




Рис. 4.
Отрицательное обобщение




Рис. 5. Обобщение по двум признакам




Рис. 6.
Концептуальный каркас

На рис. 4 показано содержание качественного отрицательного обобщенного понятия базового понятия d^0 по признаку 1. Здесь новое понятие с именем d^2 и областью $SS(d^2) = [Z_{11}; Z_{1m}] \times \Delta_2$, $SS(d^2) \subset SS$ определяет новый класс состояний системы (1). В эту область также вложена область базового понятия, $SS(d^0) \subset SS(d^2)$.

Качественное обобщение базового понятия по двум признакам представлено на рисунке 5. Новое понятие с именем d^6 имеет область класса состояния $SS(d^6) = [Z_{11}; Z_{1m}] \times [Z_{2s}; Z_{2m}]$, $SS(d^6) \subset SS$. В эту область вложено область базового понятия и область обобщения $SS(d^2)$, т.е. $SS(d^0) \subset SS(d^6)$, $SS(d^2) \subset SS(d^6)$.

Выделение областей может быть продолжено, всего могут быть получены 3^N обобщений базового понятия d^0 по разным признакам в разных сочетаниях. Отметим, что любая область помечена именами d^H , $H=0, \dots, 3^N$. Полученные имена d^H по вложению областей состояний $SS(d^H)$ образуют частично упорядоченное множество имен $\{d^H\}$ классов состояний $CF = (\{d^H\}, \leq)$, которое называется качественным концептуальным каркасом (*Conceptual Framework*) и определяет качественную онтологию предметной области. На Рис.6 показана диаграмма Хассе, в узлах которой показаны имена областей, а структура связей показывает порядок их вложения.

Таким образом, семантика синтаксической модели (2) определена качественным концептуальным каркасом, в котором упорядочены классы состояний динамической системы (1):

$$CF = (\{d^H\}, \leq), \quad (3)$$

где $d^H \leftrightarrow SS(d^H)$ – имена классов состояний, $Z(t) \in SS(d^H)$ – состояние синтаксической модели.

Здесь важно отметить, что концептуальная структура с рекурсивно вложенными областями получена формальным способом и поэтому является идеализированной концептуальной структурой с искусственными именами вложенных областей (по сути, именами классов понятий). Если говорить о структурных характеристиках интегрированности-дифференцированности, которые психологи применяют для оценивания интеллектуальных способностей человека, то для такой идеализированной структуры они будут максимальны. Концептуальный каркас является идеальным шаблоном, структурирующим ментальное пространство, однако, нет никакой гарантии, что все элементы этого шаблона могут быть определены в предметной области. Более того, как считает Дж. Лакофф [Лакофф, 1987] ментальные «пространства сходны с ситуациями ситуационной семантики фрагментарностью: они не требуют обязательной репрезентации всего, что есть в мире». Это означает, что в нашей модели будут актуализироваться те области концептуального пространства, которые имеют отношение к решению сформулированной экспертом проблемы.

Прагматическая модель отвечает за отношения между знаками, знаковыми системами и теми, кто ими пользуется. В прагматической модели рассматривается оценка полезности состояния системы для лица, принимающего решение. Оценка основана на определении коэффициентов предпочтений эксперта α_{ij} относительно значений параметров в векторе состояний $(Z(t))$.

Оценка состояния $O(Z(t))$ представляется линейной сверткой [Кулинич, 2018]:

$$O(Z(t)) = \sum_j \alpha_{ij} x_j(t), j=1, \dots, n. \quad (4)$$

где $x_j(t) \in [0, 1]$ – отображение φ лингвистических значений параметров $z_j(t)$ на отрезок числовой оси $[0, 1]$, т.е. $\varphi: z_j(t) \rightarrow x_j(t) \in [0, 1]$, $z_j(t) \in Z(t)$, $O(Z(t)) \in [0, 1]$.

Прагматическая модель моделирует интенциональный опыт человека, поскольку включает в себя предпочтения лица принимающего решения.

Все три модели связаны между собой общими параметрами, и поэтому изменения состояния любой из них приведет к изменению состояний других моделей.

2. Моделирование динамики в ментальных пространствах

В определении Дж. Лакоффа ментальное пространство представляет собой среду концептуализации и мышления [Лакофф, 1987]. Психические ментальные пространства динамичны и «разворачиваются» в концептуальные схемы предметной области. Для образования ментального про-

странства в сознании человека при решении некоторой проблемы, согласно, исследованиям необходимы построители ментальных пространств. В качестве строителей ментальных пространств используются определенные слова. Например, если человек слышит имя президента США Джо Байдена, в его сознании разворачивается ментальное пространство относительно его личности, семьи, международной деятельности и т.д. То есть образуется концептуальная среда, включающая знания человека, для рассуждений, оценок, дискуссии и целенаправленного поиска.

Таким образом, динамика психических ментальных пространств включает два процесса. Первый процесс с помощью строителя ментального пространства позволяет открыть концептуальные структуры предметной области, на которую указывает строитель. Второй процесс – это процесс манипулирования элементами концептуальной структуры, включая логические операции для целенаправленного поиска решения.

Ментальные пространства открываются в среде хорошо организованных знаний эксперта о предметной области.

Математическая модель, которая была построена с использованием шаблонов, отражают знания эксперта о текущем состоянии исследуемой ситуации. В частности определено: состояние синтаксической модели $Z(0)$; состояние семантической модели – это базовое понятие d^0 ; оценка начального состояния $Z(0)$ определена в прагматической модели – $O(Z(0))$.

В качестве семантической модели использовался концептуальный каркас, который является идеализированной моделью концептуальной системы предметной области. Использование концептуального каркаса предметной области в качестве модели знаний оправдано условиями неопределенности. Здесь, как и в случае ограниченной рациональности, построение полноценной модели предметной области оказывается нецелесообразно. Однако, идеализированная концептуальная структура может быть использована для поддержки принятия решений путем генерации строителя ментальных пространств в сознании лица принимающего решение. В этом случае качество принимаемого решения в терминах ограниченной оптимальности могут быть минимальны, т.е. полученными с минимальными затратами ресурсов, либо сатисфизационными, удовлетворительными по качеству.

Для решения задачи поддержки принятия решений в ментальных пространствах в семиотической модели решается обратная задача.

2.1. Решение обратной задачи в семиотической модели

В синтаксической модели параметры системы заданы на линейно упорядоченных множествах лингвистических значений, т.е. в качественных шкалах. Методы решение обратных задач для динамических систем тако-

го рода рассматривались в работах [Pappis, 1985], [Pedrycz, 1990]. Эти методы используются для решения обратной задачи в синтаксической модели сложной системы.

Задача заключается в том, чтобы изменить вектор начального состояния $Z(0)$, который соответствует базовому понятию, с прагматической оценкой $O(Z(0))$, на целевой вектор параметров U_{goal} , имеющий лучшую прагматическую оценку $O^*(U_{goal})$, т.е. $O^*(U_{goal}) > O(Z(0))$. Формально решение этой задачи, с учетом существующих причинно-следственных отношений W запишется так:

$$U = W^T \circledast U_{goal}$$

где \circledast процедура обратного вывода описана в работах [Pappis, 1985], [Pedrycz, 1990].

Решение обратной задачи представляется как множество решений $U = \{U_i\}$, где $U_i = (u_{1e}^i, \dots, u_{nk}^i)$ – вектор состояния, $u_{ij} \in Z_i$. Эти решения в виде точек с координатами элементов векторов представляются в концептуальном пространстве. Точки, характеризующие решения в концептуальном пространстве попадают в разные области $SS(d^H)$, характеризующие классы состояний с разными именами d^H .

Таким образом, формальные решения обратной задачи U представляются как множество имен классов решений $\{d^{H*}\}$, которое представляется в семантической модели как частично упорядоченное множество имен классов состояний $CF^* = (\{d^{H*}\}, \leq)$, $CF^* \subset CF$.

Однако, имена классов решений определены формально в виде математических символов d^H . Для формирования строителя ментального пространства у эксперта необходимы общепринятые имена, обозначающие реальные ситуации или объекты. Исследования психологов процессов классификации предлагает метод определения составного имени нового класса, основанный на добавлении к понятию базового класса оценки отличительного признака или признаков [Выготский, 1982].

В семантической модели определена область $SS(d^0) = \times \Delta_i$, где $\Delta_i = z_{ij} \pm \varepsilon_i$, в которой определено имя базового понятия d_i^0 . Решение обратной задачи – это вектор: $U = (u_{1j}, \dots, u_{nk})$, $u_{ij} \in Z_i$. Результат решения обратной задачи будем представлять в виде вектора $A = (a_1, \dots, a_n)$, $a_i \in \{-1, 0, 1\}$, где $a_i = -1$, если $u_{ij} < z_{ij} - \varepsilon_i$, $a_i = 1$, если $u_{ij} > z_{ij} + \varepsilon_i$, $a_i = 0$, если $u_{ij} \in z_{ij} \pm \varepsilon_i$.

В этом векторе a_i качественно характеризует оценку значения i -го признака (f_i) в решении обратной задачи. Если (+1), то признак имеет большое значение, (-1) – параметр имеет малое значение, чем значение базового понятия. Если представить этот вектор в виде вектора с лингвистиче-

скими оценками $Z^*=(z_1^*, \dots, z_n^*)$, где $z_i^* = \text{«Большой»}$, если $a_i=1$, $z_i^* = \text{«Малый»}$, если $a_i=-1$, тогда, составное искусственное имя класса решений будет иметь следующий вид:

$$d^H = d^0 \ \& \ \underset{i (a_i \neq 0)}{z_i^*}.$$

Например, если имя базового класса $d^0 = \text{«Шар»}$, то возможные составные имена новых классов по признаку «Размер» могут быть такими: $d^1 = \text{«Шар большой»}$ или $d^2 = \text{«Шар малый»}$.

Таким образом, составное искусственное имя состоит из имени базового понятия и перечисления значений отличительных признаков класса, значения которых вышли за пределы области, которая определяет базовое понятие.

Здесь мы считаем, что такие имена являются строителями психических ментальных пространств в сознании человека. Важно отметить, строители ментальных пространства использовались и в других методах (правда, в этих методах они не называются строителями ментальных пространств). Например, в методах интуитивного поиска ассоциаций и аналогий выделяется ключевое слово проблемы, к которому придумывают пять ассоциаций, далее к каждой ассоциации предлагают по пять глаголов и по пять прилагательных. Итого получают 50 гирлянд ассоциаций. Нужно просмотреть все полученные гирлянды, чтобы найти среди этого множества такое сочетание ассоциации глагола или прилагательного, которое будет понятно эксперту и откроет его ментальное пространство для целенаправленного поиска решения. Такие подходы используют для поиска креативных решений в ментальных пространствах.

Дело в том, что ментальное пространство открывается, если у субъекта есть хоть какие-то знания о предметной области. Принятие решений при недостаточности знаний приводят к принятию интуитивных решений, содержащих разного рода когнитивные искажения. В этой работе исследуется возможность поддержки работы строителей ментальных пространств, в случаях недостаточности экспертных знаний с использованием неструктурированных данных сети Интернет.

2.2. Использование неструктурированных данных сети Интернет для поддержки концептуальных структур эксперта

В случае недостаточности экспертных знаний для построения ментального пространства, анализируемой проблемы предлагается использовать неструктурированные данные сети Интернет. Используется свободный текст, из которого методами обработки естественного языка извлекается необходимая информация. Эта информация нужна для поддержки работы строителя

ментальных пространств и направлена на улучшение структурных характеристик концептуального пространства лица принимающего решение, которые влияют на интеллектуальную продуктивность субъекта.

Для работы метода необходим корпус текста предметной области. Для создания корпуса текста с помощью программных модулей извлечения информации из сети Интернет (например, модуль `googlesearch` для Python3) получаем текстовую информацию с множества сайтов, включающих ключевое слово, совпадающее с именем базового понятия d^0 , т.е. выделяем текст, который имеет отношение к решаемой проблеме.

Дело в том, что полученный корпус текста содержит информацию о концептуальной структуре предметной области. В частности это родовидовые отношения в предметной области, извлечение которых может помочь лицу принимающему решение открыть ментальное пространство для целенаправленного поиска. Для выделения родовидовых отношений из корпуса текста используется лексико-синтаксические шаблоны [Большакова, 2006], которые определяют структурный образец языковой конструкции, отражающий ее лексические и поверхностно-синтаксические свойства.

По результатам работы лексико-синтаксических шаблонов строится словарь гиперонимов-гипонимов. Однако просто словаря гиперонимов-гипонимов для нашего случая поддержки построения ментального пространства недостаточно. Поэтому в словарь добавляется еще и контекст, т.е. предложение из корпуса текста, в котором обнаружены родовидовые отношения.

Словарь определим следующим кортежем: $\langle \text{Hiper}, \text{Hipo}, \text{Contex} \rangle$, где *Hiper* – гиперонимы, *Hipo* – гипонимы, *Contex* – предложения, в которых обнаружены гиперонимы.

При экспериментах на корпусе текста, содержащего 30 000 предложений, с помощью лексико-синтаксических шаблонов, было выявлено 1 800 предложений, содержащих родовидовые отношения. Это много и анализировать их все-таки достаточно сложно. В процессах решения задач активизируется одно ментальное пространство или последовательность ментальных пространств.

Для этого с помощью дистрибутивного анализа находим слова в корпусе текста часто употребляемые со словами, включенными в построитель ментального пространства, полученного формальным способом.

При дистрибутивном анализе текста синтаксические связи в предложениях корпуса текста игнорируются. Корпус текста для дистрибутивного анализа нормализуется, т.е. в корпусе текста остается множество предложений, содержащие существительные единственного числа. Множество всех неповторяющихся слов в предложениях образует словарь предметной области, $Vc = \{w_i\}$.

Корпус текста служит для обучения нейронной сети word2vec [Mikolov, 2013]. Обученная корпусом текста нейронная сеть позволяет определять совместную встречаемость слов в корпусе текста. Например, если задать нейронной сети некоторое слово, она определит вектор слов, которые часто встречаются с этим словом. Таким образом, после обучения нейронной сети word2vec - векторная модель совместной встречаемости слов в корпусе текста может быть представлена как функция $w2v(\bullet)=R$, где \bullet - аргументом функции может быть любое слово из словаря V_c , а вектор $R=(w_i/r_{i1}, \dots, w_n/r_{in})$ характеризует совместную встречаемость r_{ij} с другими словами (w_1, \dots, w_n) из словаря предметной области V_c .

В векторную модель word2vec в качестве аргумента функции $w2v(\bullet)$ может быть подставлено сочетание слов $w_i \& \dots \& w_q$, $w_i, \dots, w_q \in V_c$, из словаря предметной области. Если подставить в качестве аргумента составное имя решения d^H , $w2v(d^H)=R_s$ - то вектор $R_s=(w_i/r_{i1}, \dots, w_n/r_{in})$ будет включать имена $w_i \in V_c$, которые совместно употребляются с именем d^H и упорядочены согласно частоты их совместной встречаемости r_{ij} .

Дело в том, что согласно теории категорий Э. Рош [Rosh, 222], имена категорий – это часто употребляемые имена наиболее значимого представителя категории (класса).

Вектор совместной встречаемости составного имени решения и слов предметной области из словаря R_s может содержать слова, которые могут определять имена категории класса решения. Такие имена можно использовать для построителя ментального пространства. Для получения имен категорий решений нужно получить пересечение слов имен из вектора R_s и слов гиперонимов из словаря гиперонимов-гипонимов.

Тогда, альтернативой составному имени классов решений будет кортеж: $\langle W_s \cap \text{Hiper}, \text{Contex} \rangle$, где $W_s=(w_1, \dots, w_n)$ слова вектора R_s , Hiper – гиперонимы словаря, Contex – предложения, в которых обнаружены гиперонимы. Если это пересечение не пусто, то мы нашли еще один построитель ментального пространства, включающий имя категории (класса) решений и контекст – предложение, поясняющее этот новый построитель ментального пространства.

Для поиска альтернативных построителей ментального пространства в сети Интернет был разработан программный макет на языке Python3. Была разработана семиотическая модель. При решении обратной задачи для базового понятия «Олигархи» было получено составное имя «Недовольные олигархи». Интерпретация этого имени в предметной области позволило получить два альтернативных построителя ментальных пространств, «Вредные олигархи» и «Недоверчивые олигархи». Новые построители с такими именами позволяют легко найти экземпляры категории (имена олигархов), определить их поведение, влияние на экономику страны.

Заключение

В работе рассмотрена семиотическая модель ментального пространства, предназначенная для поддержки принятия решений в плохо определенных социальных, политических и экономических ситуациях. В отличие от двух процессной модели принятия решений Канемана, в модели ментального пространства строится семиотическая модель проблемы (репрезентация). Формальное решение обратной задачи в семиотической модели порождает концептуальный каркас решений, включающий искусственные составные имена классов решений. Эти имена используются в качестве строителей ментальных пространств лица принимающего решение для целенаправленного поиска решения. Для поддержки строителей ментальных пространств в условиях неполноты знаний предложено использовать неструктурированные данные сети Интернет. С помощью методов обработки естественного языка из неструктурированных данных извлекается информация для поддержки построения ментального пространства принятия решений в сознании эксперта. Особенность предложенного подхода заключается не в уменьшении влияния когнитивных искажений на окончательное решение, а поддержку построения концептуальных структур человека, ответственных за его интеллектуальную продуктивность.

Список литературы

- [Fauconnier, 1994] Fauconnier G. Mental Spaces: Aspects of meaning construction in natural language. – Cambridge: Cambridge University Press, 1994.
- [Fauconnier, et al., 2002] Fauconnier G., Turner M. The Way We Think: Conceptual Blending and the Mind's Hidden Complexities. – NY: Basic Books, 2002.
- [Frege, 1949] Frege G. On sense and nominatum. Readings in philosophical analysis. – 1949.
- [Gärdenfors, 2000] Gärdenfors P. Conceptual spaces: the geometry of thought. Cambridge, Massachusetts: MIT Press, 2000.
- [Kahneman, et al., 2019] Kahneman D., Lovallo D., Olivier Sibony O., Torraine A., Hoppel C. A Structured Approach to Strategic Decisions, MIT Sloan Management Review, April 2019.
- [Lakoff, 1987] Lakoff G. Women, Fire, and Dangerous Things. What Categories Reveal about the Mind. The University of Chicago Press, 1987. – P. 5-15, 39-48, 56-57.
- [Mikolov, 2013] Mikolov, et al. Distributed representations of words and phrases and their compositionality // In Advances in Neural Information Processing Systems: 27th Annual Conference on Neural Information Processing Systems. Proc. Dec. 5-8, 2013, Lake Tahoe, Nevada, United States. - 2013. - P. 3111-3119.
- [Misuraca, et al., 2015] Misuraca R., Faraci P., Gangemi A., Carmeci F.A., Miceli, S. The Decision Making Tendency Inventory: A new measure to assess maximizing, satisficing, and minimizing // Personality and Individual Differences. – 2015. – Vol. 85. – P. 111-116.

- [Pappis, 1985] Pappis C.P., Sugeno M. Fuzzy relational equations and the Inverse Problem // Fuzzy Sets and Systems. – 1985. – No. 15. – P. 79-90.
- [Pedrycz, 1990] Pedrycz W. Algorithms for solving fuzzy relational equations in a probabilistic setting // Fuzzy Sets and Systems. – 1990. – No. 38. – p. 313-327.
- [Rosch, 1978] Rosch E. Principles of categorization. In: Rosch E., Lloyd B.D. Cognition and categorization. – N.Y.: Lawrence Erlbaum association, 1978.
- [Schroder, et al, 1970] Schroder H.M., Driver M.J., Streufert S. Levels of information processing. In: Warr P.B. (Ed.). Thought and Personality. Baltimor: Penguin Books Inc.
- [Zilberstein, 1998] Zilberstein S. Satisficing and bounded optimality // AAAI Spring Symposium on Satisficing Models. – 1998. – P. 91-94.
- [Quillian, 1968] Quillian M.R. Semantic memory. Semantic information processing. – 1968. – P. 227-270.
- [Большакова, 2006] Большакова Е.И., Васильева Н.Э., Морозов С.С. Лексико-синтаксические шаблоны для автоматического анализа научно-технических текстов // 10-я Национальная конференция по искусственному интеллекту (КИИ-2006): Труды конференции. – М.: Физматлит. - 2006. - Т. 2. - С. 506-524.
- [Бьюзен, 2021] Бьюзен Т. Интеллект-карты. Полное руководство по мощному инструменту мышления. Манн, Иванов и Фербер, 2021. – 208 с.
- [Величковский, 2006] Величковский Б.М. Когнитивная наука: Основы психологии познания. В 2-х т. – М.: Смысл / Академия, 2006. – 448 с.
- [Выготский, 1982] Выготский Л. С. Мышление и речь // Собр. соч.: Т. 2. – М.: Педагогика, 1982. – С. 5-361.
- [Исикава, 1988] Исикава К. Японские методы управления качеством: Сокр.пер. с англ. / под. Ред. А.В. Гличева. – М: Экономика, 1988. – 214 с.
- [Канеман, 2005] Канеман Д. Думай медленно... решай быстро. – М.: АСТ, 2013. – 625 с.
- [Канеман, и др., 2005] Канеман Д., Словик П., Тверски А. Принятие решений в неопределенности: Правила и предубеждения. – Харьков: Гуманитарный центр, 2005. – 632 с.
- [Кулинич, 2014] Кулинич А.А. Концептуальные каркасы онтологий слабо структурированных предметных областей // Искусственный интеллект и принятие решений. - 2014. - № 4. - С. 31-41.
- [Кулинич, 2018] Кулинич А.А. Семиотический подход в моделировании и принятии решений в плохо определенных сложных ситуациях // Материалы 11-й Международной конференции «Управление развитием крупномасштабных систем» (MLSD'2018, Москва). – М.: ИПУ РАН, 2018. Т. 2. – С. 298-301.
- [Моррис, 2001] Моррис Ч.У. Основания теории знаков. - Семиотика: антология. – 2-е изд. перераб. и доп. – М.–Екатеринбург, 2001. - С. 45–97.
- [Пирс, 2009] Пирс Ч.С. Что такое знак? // Вестник Томского Гос. Университета. Философия. Социология. Политология. - 2009. - № 3(7). - С. 88-95.
- [Поспелов, и др. 1999] Поспелов Д.А., Осипов Г.С. Прикладная семиотика // Новости ИИ. – 1999. – №1.
- [Разваляева, 2021] Разваляева А.Ю. Рациональность и интуиция как личностные факторы принятия решений: дисс. ... канд. психол. наук. – 2021. – 213 с. – <https://istina.msu.ru/dissertations/368761951/>.
- [Саймон, 1993] Саймон Г.А. Рациональность как процесс и продукт мышления // THESIS. – 1993. – Вып. 3.
- [Холодная, 2002] Холодная М.А. Психология интеллекта: Парадоксы исследования. – 2-е изд, перераб. и доп. – СПб.: Питер, 2002. – 272 с.

КОГНИТИВНОЕ МОДЕЛИРОВАНИЕ ДЕЯТЕЛЬНОСТИ УНИВЕРСИТЕТА КАК СЛАБОСТРУКТУРИРОВАННОЙ СИСТЕМЫ*

А.А. Микрюков (*mikrukov.aa@rea.ru*)

М.Е. Мазуров (*mazurov37@mail.ru*)

Российский экономический университет, Москва

Актуальность решаемой задачи определяется необходимостью разработки научно-обоснованных предложений по достижению требуемых значений базовых показателей деятельности университета, обеспечивающих вхождение университета в ТОП -500 вузов к 2025г. Для решения поставленной задачи предложен подход к исследованию слабо структурированных систем, к классу которых относятся университеты и их деятельность, на основе методов сценарного прогнозирования путем построения нечеткой когнитивной модели с целью определения необходимых приращений значений целевых показателей. Предложенный подход позволяет в условиях заданных ограничений найти наиболее приемлемый сценарий планирования приращения базовых показателей до целевых значений за счет идентификации влияющих на них латентных факторов и импульсных воздействий, которые обеспечивают гарантированное достижение поставленной цели. Полученные результаты позволяют в последующем обосновать ежегодные расходы для обеспечения безусловного приращения значений латентных факторов с целью гарантированного достижения требуемых значений базовых показателей деятельности университета к 2025г. Новизна предлагаемого подхода заключается в использовании при построении нечеткой когнитивной модели корреляционных взаимосвязей латентных факторов, выявленных на основе методов факторного анализа, с базовыми показателями, а также применении к решению поставленной задачи итерационного подхода на основе нечеткой когнитивной карты. Применение предложенного подхода позволят ежегодно по результатам очередного рейтингования университетов в международном институциональном рейтингом QS актуализировать набор исходных данных, а также обучать разработанную когнитивную модель с учетом результатов идентификации латентных факторов и

* Работа выполнена при финансовой поддержке РФФИ (проект № 20–07–00926).

корректировки их корреляционных взаимосвязей. Полученные результаты позволяют сформировать наиболее предпочтительный сценарный план необходимого ступенчатого наращивания значений базовых показателей в интервале 2020–2025 гг. с учетом ограничений на ресурсы.

Ключевые слова: когнитивная модель, сценарное прогнозирование, базовые показатели, институциональный рейтинг.

Введение

Целью разработки когнитивной модели сценарного прогнозирования является обоснование перечня необходимых мероприятий для обеспечения приращений значений базовых показателей деятельности университета в соответствии с международным институциональным рейтингом QS до требуемых величин, необходимых для вхождения университета в ТОП – 500 вузов к 2025 г.

Для достижения поставленной цели исследования обосновано применение методов решения слабо структурированных задач на основе разработки модели сценарного прогнозирования с использованием нечетких когнитивных карт, которая позволила определить вероятные тенденции развития событий по альтернативным вариантам и возможные последствия принимаемых решений с целью выбора наиболее предпочтительной альтернативы.

При этом необходимо учитывать, что значение функционала и место в рейтинге QS из года в год не являются взаимно однозначными, т. к. количество вузов, принимающих участие в рейтинге QS, ежегодно изменяется в сторону их увеличения. Из этого следует, что значение функционала, соответствующее определенному месту в рейтинге в текущем году, может не соответствовать такому же месту в рейтинге в последующих годах. Т.е. значение функционала необходимо рассчитывать с определенным запасом.

В ходе исследования решены следующие задачи: разработана нечеткая когнитивная модель сценарного прогнозирования мероприятий по достижению требуемых значений целевых показателей деятельности университета в международном институциональном рейтинге QS, на основе разработанной модели проведен расчет наиболее предпочтительного варианта набора требуемых интенсивностей воздействия на управляющие переменные при заданном приращении значения целевого фактора. Полученный на основе когнитивной модели сценарий планирования мероприятий по гарантированному достижению целевого значения позволил обосновать величину необходимых приращений значений выявленных латентных факторов, влияющих на базовые показатели. На основе полученных

результатов в последующем возможно обоснование необходимых ежегодных расходов для обеспечения гарантированного достижения требуемого значения рейтингового функционала университета к 2025г.

Полученные результаты позволили сформировать сценарный план необходимого ступенчатого наращивания значений индикаторов с учетом влияющих на них факторов.

Особенностью разработанного подхода является выявление наиболее значимых латентных факторов, влияющих на базовые показатели, а также оценка степени их влияния на базовые показатели на основе методов факторного анализа. С целью обеспечения адекватности когнитивной модели использован итеративный подход, позволяющий построить обучаемую когнитивную модель. Использование указанного подхода предусматривает корректировку когнитивной модели по результатам оценки деятельности университетов после выхода ежегодного отчета о месте университета в институциональном рейтинге QS. Корректировка осуществляется путем уточнения структуры когнитивной карты и каузальных зависимостей на основе актуализации наборов исходных данных, а также результатов идентификации наиболее значимых латентных факторов с использованием факторной модели. Применение итеративного подхода позволяет обеспечить повышение достоверности и точности получения решения.

В разделе 1 проведен литературный обзор по теме исследования, в разделе 2 представлены результаты разработки когнитивной модели, в разделе 3 приведены результаты сценарного прогнозирования показателей деятельности университета на основе разработанной когнитивной модели сценарного прогнозирования, в разделе 4 представлена интерпретация результатов численного эксперимента.

1. Литературный обзор

Проблематике когнитивного моделирования посвящено достаточно большое количество работ отечественных и зарубежных ученых [Максимов и др., 2004], [Axelrod, 1976], [Кузнецов, 2005], [Робертс, 1986], [Kosko, 1986], [Горелова, 2019], [Авдеева и др., 2007], [Болотова, 2012], [Борисов и др., 2021] и др.

Важной задачей при использовании когнитивных моделей является обеспечение их достоверности, адекватности и точности. В работах [Максимов и др., 2004], [Axelrod, 1976], [Кузнецов, 2005], [Робертс, 1986], [Kosko, 1986], предложен подход на основе классических когнитивных моделей. В работах [Carvalho et al., 1999], [Osoba et al., 2017], [Salmeron et al., 2017] рассматриваются решения задач с использованием нечетких когнитивных моделей.

В работе [Кулинич, 2016] решается задача оценки устойчивости когнитивных моделей, а также методов их верификации. В работах [Горелова и др., 2006], [Авдеева и др., 2007], [Karabutov, 2020], [Борисов и др., 2021] рассматриваются особенности моделирования нелинейных динамических систем в условиях неопределенности.

Проведенный анализ источников показал целесообразность использования класса нечетких когнитивных моделей и что в представленной постановке задача когнитивного моделирования сценариев развития университета не рассматривалась.

Выбор нечеткой когнитивной модели обосновывается следующими причинами. Классические когнитивные карты не всегда обеспечивают построение адекватной и достоверной математической модели из-за высокого уровня неопределенности взаимодействия компонентов объекта исследования. Они являются линейными и не в полной мере учитывают динамические свойства реальных систем, которые могут быть существенно нелинейными и нестационарными. Сила связей между концептами нечеткой когнитивной карты задается с помощью нечеткой лингвистической шкалы, представляющей собой упорядоченное множество лингвистических значений (термов) оценок силы связи. Использование нечетких когнитивных карт обеспечивает удобную интерпретацию причинно-следственных связей между концептами. Все это в совокупности обеспечивает построение адекватной модели объекта исследования.

2. Методология решения задачи

Методология когнитивного моделирования является самостоятельным научным направлением, которое в настоящее время активно развивается. Когнитивные карты представляют собой удобный математический аппарат для описания и исследования слабо структурированных систем (социально-экономических, социотехнических, организационных и т.п. систем), отличительными признаками которых являются функционирование в условиях неопределенности, характеризующейся недостатком информации о протекающих в них процессах, невозможностью аналитического описания и построения формальных моделей, учитывающих специфику рассматриваемых систем.

Проведенный анализ поставленной задачи показал, что она относится к классу слабо структурированных задач, которая решается в условиях ограниченного количества исходных данных и ряда неопределенностей, связанных, в том числе, с отсутствием линейной зависимости между значениями функционала и места вуза в рейтинге QS на рассматриваемом временном интервале.

Для решения указанного класса задач используется методология нечеткого когнитивного моделирования, предназначенная для анализа и принятия решений в плохо определенных ситуациях, когда не представляется возможным аналитически описать и построить формальные математические модели, учитывающие специфику исследуемой слабо структурированной системы и, в частности, метод сценарного прогнозирования (планирования) на основе когнитивных карт (карт познания), который позволяет определить вероятные (возможные) тенденции развития событий по альтернативным вариантам и возможные последствия принимаемых решений с целью выбора наиболее предпочтительной альтернативы (сценария).

Как известно, сценарий представляет собой некоторую относительную, условную оценку возможного развития исследуемого объекта или ситуации, так как всегда строится в рамках предположений о будущих условиях развития, которые чаще всего принципиально непредсказуемы.

В отличие от классических методов прогнозирования, в которых основное внимание уделяется оценке наиболее вероятного варианта развития системы, при сценарном прогнозировании исходят из представления о неопределенности и неоднозначности траектории этого развития. Особенностью сценарного прогнозирования является то, что оно позволяет одновременно рассматривать несколько вариантов развития ситуации, в том числе анализировать возможности и риски [Авдеева и др., 2007].

В контексте рассматриваемой задачи под сценарием понимается динамическая последовательность возможных событий изменения значений факторов – причин и факторов – следствий, влияющих на целевые показатели. Причинно-следственные связи между этими событиями и точками принятия решений способны изменить их ход и траекторию движения во времени всей рассматриваемой системы показателей, а, значит, выбрать наиболее предпочтительный вариант траектории. Для решения поставленной задачи предложен подход к сценарному прогнозированию на основе нечеткой когнитивной карты, который включает следующие этапы:

- генерирование сценариев и оценка рисков;
- корректировка сценариев через дискретные интервалы времени (в нашем случае, ежегодно) с учетом достигнутых значений места в рейтинге QS функционала и индикаторов.

По истечении очередного интервала времени строится новый сценарий для достижения очередной поставленной цели (скорректированной с учетом актуальных расчетов).

На первом этапе исследования проведена идентификация и интерпретация латентных факторов, влияющих на базовые показатели, и оценка их значимости с использованием методов факторного анализа, который

представляет собой класс процедур многомерного статистического анализа, направленный на выявление латентных переменных (факторов), отвечающих за наличие линейных статистических связей (корреляций) между наблюдаемыми переменными [Горидько и др., 2017], [Дрейпер, 2019], [Соколов и др., 2016], [Микроков и др., 2020].

Факторы представляют собой группы определенных переменных, коррелирующих между собой больше, чем с переменными, входящими в другой фактор. Таким образом, содержательный смысл факторов был выявлен путем исследования корреляционной матрицы исходных данных.

С целью идентификации множества факторов, влияющих на базовые показатели деятельности университета, а также последующего выявления наиболее значимых факторов для реализации в последующем подхода к решению поставленной задачи на основе методов когнитивного моделирования [Беляев, 2007], [Богомолова, 2004], проведен их SWOT – анализ.

Как известно, методика SWOT – анализа предполагает глубокий анализ объекта исследования, обеспечивает максимально объективную его оценку с точки зрения сильных (положительных) сторон и слабых (отрицательных) сторон внешней и внутренней среды, а также возможностей и угроз. Результаты SWOT – анализа позволили построить проблемное поле ситуации, на основе которого сформулированы цели и задачи когнитивного моделирования, а также определена структура когнитивной карты, с помощью которой решена задача прогнозирования показателей деятельности университета. При построении проблемного поля ситуации для структуризации знаний использован объектно-структурный подход, согласно которому анализ и представление знаний может осуществляться в стратегическом, организационном, концептуальном, функциональном, пространственном, временном, каузальном и экономическом аспектах (стратах) [Горелова и др., 2006], [Bodyanskiy et al., 2014].

Результаты проведенного анализа позволили структурировать знания экспертов с использованием проблемного поля знаний, построить и выявить на основе метода экспертных оценок совокупность латентных факторов и степень их влияния на показатели деятельности университета.

Регистрация данных SWOT-анализа проводилась в табличной форме, где фиксировались основные элементы по представленным категориям (табл. 1).

Таблица 1

Анализируемые факторы (характеристики)	Степень воплощения фактора (характери- стики) Сильный фактор + Слабый фактор -	Степень важно- сти фактора (характеристики)
1. Наличие известных научных школ и диссертационных советов	Сильный фактор +	0,6
2. Наличие тесной коллаборации с зарубежными вузами и научными организациями (число совместных научных проектов)	Сильный фактор +	0,3
3. Наличие базовых кафедр на пред- приятиях	Сильный фактор +	0,2
.....
Фактор (характеристика) <i>N</i>

Итогом проведения SWOT-анализа стала идентификация и группирование совокупности факторов, оказывающих влияние на базовые показатели университета. Поскольку количество латентных факторов, влияющих на деятельность университета, представляет собой значительную величину (результаты проведенного анализа позволили выявить около 100 факторов), возникла необходимость выделения наиболее существенных латентных факторов с учетом корреляционных взаимосвязей, в том числе факторов второго уровня, оказывающих влияние на факторы первого уровня.

С целью выявления наиболее значимых латентных факторов был использован один из наиболее распространенных методов факторного анализа - метод главных компонент, который позволяет уменьшить (редуцировать) большое число связанных между собой коррелирующих переменных, так как большое количество переменных существенно затрудняет анализ и интерпретацию результатов моделирования.

Расчеты на основе метода главных компонент проведены в среде аналитической платформы Deductor 5.3 с использованием модуля «Факторный анализ». Применение аппарата факторного анализа позволило решить две главные задачи: снижение размерности числа используемых переменных за счет их объяснения меньшим числом факторов и группирование и структурирование полученных данных.

Новизна предлагаемого подхода определяется:

- решением задачи структуризации знаний с использованием объектно-структурного подхода при построении проблемного поля ситуации, что обеспечивает более эффективное группирование латентных факторов и построение адекватной архитектуры когнитивной карты;

- выявлением наиболее значимых латентных факторов, влияющих на базовые показатели, а также оценкой степени этого влияния на основе методов факторного анализа;
- реализацией когнитивной модели на основе нечеткой когнитивной карты, обеспечивающей адаптацию к неопределенности исходных данных и условиям решаемой задачи, что, в свою очередь позволило сформировать адекватную когнитивную модель и обеспечить повышение достоверности и точности результатов моделирования;
- использованием итеративного подхода к построению когнитивной модели, позволяющего построить обучаемую когнитивную модель;
- возможностью корректировки нечеткой когнитивной модели по результатам ежегодной оценки деятельности университетов в институциональном рейтинге QS. Корректировка осуществляется путем уточнения структуры когнитивной карты и каузальных зависимостей концептов на основе актуализации наборов исходных данных, также результатов идентификации латентных факторов с использованием факторной модели.

3. Результаты сценарного прогнозирования показателей деятельности университета на основе нечеткой когнитивной модели

В отличие от классических когнитивных карт нечеткие когнитивные карты (НКК) представляются в виде нечеткого ориентированного графа с обратными связями, узлы которого являются нечеткими множествами. НКК объединяет в себе свойства нечетких систем и нейронных сетей [Salmeron at al., 2017].

В результате отбора наиболее значимых латентных факторов, влияющих на базовые показатели построена когнитивная карта, отражающая их взаимосвязи, а также веса этих взаимосвязей (рис. 1).

На рис. 1 приняты следующие обозначения: целевые показатели: *F/R* – функционал/рейтинг университета, *AP* – академическая репутация; *PP*- репутация у работодателя; *ОСП* – отношение числа студентов к числу преподавателей; *ЦП* – показатель цитируемости преподавателей; *МП* – число международных преподавателей; *МС* – число международных студентов; латентные факторы: *F1* – «Научные школы и диссертационные советы» (0,6); *F2* – «Совместные научные проекты» (0,3); *F3* – Наличие базовых кафедр (0,2); *F4* – Число публикаций в БД Scopus (0,6); *F5* – Востребованные направления подготовки (0,3); *F6* – уровень квалификации НПП (0,2); *F7* – Число НПП (0,6); *F8* – Уровень компетенции студентов (0,5); *F9* = НПП с языковой подготовкой (0,4); *F10* – Места в общежитии (0,2); *F11* – Востребованность выпускников у работодателей (0,3); *F12* – Площа-

ди для образовательной деятельности (0,3); $F13$ – Уровень оплаты НПП (0,4); $F14$ – Стимулирующие факторы (0,2); $F15$ – Расширение соцпакета НПП (0,3); $F16$ – Изменение структуры занятости НПП (0,3); $F17$ – Доля НПП, планирующих строить интернациональную научную карьеру (0,2); $F18$ – Академическая мобильность НПП (0,3); $F19$ – Конвергенция образовательных программ с иностранными вузами (0,4); $F20$ – Иностранная абитуриентская компания (0,3); $F21$ – Увеличение числа On-line курсов MOOCs (0,3), $F22$ – Внедрение индивидуальных образовательных траекторий (0,4); $F23$ – Внедрение дистанционных технологий (0,3); $F24$ – Теснота взаимосвязи с работодателем (0,4). Веса взаимосвязей концептов когнитивной карты определены на основе применения экспертных методов и методов корреляционно-регрессионного анализа.




Рис. 1. Когнитивная карта системы показателей деятельности университета на основе графа взаимосвязи латентных факторов ($F1$ - $F24$), базовых показателей (AP , PP , $ОСП$, $ЦП$, $МП$, $МС$) и функционала (рейтинга) F/R

Целесообразность построения когнитивной модели на основе нечеткой когнитивной карты определяется следующими причинами:

- неполнотой и противоречивостью знаний об исследуемом объекте, а также их разнокачественностью;
- нечеткостью и неясностью выделения и описания границ состояний слабо структурированных систем и происходящих в них процессов;
- наличием нестохастической неопределенности показателей функционирования слабо структурированных систем, о которых невозможно получить достоверные данные.

Нечеткие модели, обладая свойствами «универсальной аппроксимации» и достаточно эффективной интерпретируемости полученных результатов, позволяют решать задачу идентификации сложных нелинейных зависимостей в слабо структурированных системах как на основе имеющихся экспериментальных, так и выявленных количественных и качественных данных.

Ориентированный граф (орграф) НКК задается с помощью набора множеств

$$HKK = \langle C, F, W \rangle, \dots \dots \dots (3.1)$$

где $C = \{C_i\}$ – множество вершин графа, называемых концептами, в качестве которых выступают факторы, наиболее существенные с точки зрения изучения рассматриваемой системы;

$F = \{F_k\}$ – множество направленных дуг графа – связей между концептами; $W = \{W_{ij}\}$ – множество весов дуг (связей).

Связи между концептами могут быть положительными, «усиливающими» влияние концепта C_i на концепт C_j ($W_{ij} > 0$), или отрицательными, «ослабляющими» влияние концепта C_i на концепт C_j ($W_{ij} < 0$).

Каждый концепт характеризуется терм-множеством лингвистической переменной

$$T_i = \{T_1^i, T_2^i, \dots, T_{m_j}^i\}, (3.2)$$

где m_j – число типовых состояний i -го концепта. Для описания каждого термина T_k^i построен терм – множество с функцией принадлежности. Связи между типовыми состояниями каждой пары концептов заданы нечеткими переменными, описываемыми соответствующими и нечеткими множествами.

Значения весов (силы связей) W_{ij} в нечеткой когнитивной карте заданы с помощью нечеткой лингвистической шкалы, представляющей собой упорядоченное множество лингвистических значений (термов) оценок силы связи, например вида: СИЛА_СВЯЗИ = {Не влияет; Слабая; Средняя; Сильная; Очень сильная}. Каждому из этих значений ставится в соответствие некоторый числовой диапазон, принадлежащий отрезку $[0, 1]$ для положительных связей или отрезку $[-1, 0]$ для отрицательных связей (табл. 2),

Сила связи между концептом C_i и концептом C_j , выбрана экспертом одним из представленных в таблице лингвистических значений, а также некоторой «точечной» оценкой силы связи – числом внутри этого диапазона (в случае использования мнения нескольких экспертов вес W_{ij} усредняется).

Таблица 2

Лингвистическое значение	Числовой диапазон	Обозначение термина	Точечная оценка силы связей+
Не влияет	0	Z	0
Очень слабая	(0; 0,15)	VL	0,12
Слабая	(0,15; 0,35)	L	0,23
Средняя	(0,35; 0,60)	M	0,47
Сильная	(0,6; 0,85)	H	0,72
Очень сильная	VH	VH	0,93

В общем случае взвешенный орграф – нечеткая когнитивная карта с произвольными значениями весов $W_{ij} \in [-1, 1]$ описывается динамикой изменения его состояния во времени. Состояние орграфа при этом определяется совокупностью состояний его концептов C_i , ($i = 1, 2, \dots, n$), каждое из которых описывается переменной состояния $X_i(t)$, принимающей значения в интервале $[0, 1]$.

Переменные состояния X_i (значения латентных факторов) вычислены путем нормирования реальных («физических») переменных по формуле

$$X_i = \frac{(X_i - X_{i \min})}{(X_{i \max} - X_{i \min})}, \quad (3.3)$$

где $X_{i \min}$ и $X_{i \max}$ – минимальное и максимальное значения переменной X_i , ($i = 1, 2, \dots, n$).

Состояние НКК в произвольный момент времени описано уравнением состояния следующего вида:

Взвешенный орграф на рис. 1 с произвольно заданными значениями весов W_{ij} представлен уравнениями состояния:

$$X_i(t + 1) = f(X_i(t) + \sum_{j=1}^n W_{ij} X_j(t)), \quad (i = 1, \dots, n), \quad (3.4)$$

где f – некоторая нелинейная «сжимающая» функция, отображающая значения аргумента в единичный интервал $[0, 1]$.

Этому условию удовлетворяет, сигмоидная функция

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (3.5)$$

Для расчета переменных состояния $X_i(t)$, ($i = 1, 2, \dots, n$) с помощью уравнений (3.4), необходимо задать начальные условия, т.е. вектор $X(0) = (X_1(0), X_2(0), \dots, X_n(0))^T$.

Важным этапом анализа НКК является анализ ее импульсной устойчивости [Корноушенко и др., 2000], [Кульба и др., 2002], [Максимов, 2005], [Кизим, и др. 2011], когда для заданного ненулевого начального состоя-

ния $X_i(0)$, например, $X_1(0) = 1$, $X_2(0) = \dots = X_n(0) = 0$, последовательность значений импульсов $p_i(t) = X_i(t) - X_i(t-1)$ ограничена в любой момент времени $t = 1, 2, \dots, m$ для любой его вершины, и абсолютной устойчивости, когда для каждой вершины орграфа ($i = 1, 2, \dots, n$) ограничена последовательность значений $X_i(t)$, $t = 1, 2, \dots, m$.

При этом справедливо утверждение: взвешенный орграф, который описывается уравнениями (3.4), (3.5) абсолютно устойчив, причем существует единственное равновесное (установившееся) решение указанных уравнений («неподвижная точка») X^* в том и только в том случае, если

$$\sqrt[2]{\sum_{i=1}^n \sum_{j=1}^n w_{ij}^2} < 4, \quad (3.6)$$

где n – число концептов НКК. Проверка разработанной НКК на основе формулы (3.6) подтвердила ее устойчивость.

Результаты проведенной оценки влияния латентных факторов на базовые и рейтинговые показатели позволили сделать следующие выводы: наименьшее влияние оказывают факторы: *F3*, Наличие базовых кафедр на предприятиях; *F14*, Стимулирующие факторы. В свою очередь наибольшее влияние оказывают факторы: *F1*, Наличие известных научных школ и диссертационных советов; *F2*, Наличие тесной коллаборации с зарубежными вузами и научными организациями (число совместных научных проектов; *F4*, Число публикаций в БД Scopus, WoS.

На основе задания значений исходных данных с использование формулы (3.3), задания весов взаимовлияний факторов с использованием экспертных оценок и результатов корреляционно-регрессионного анализа, описания поведения орграфа с помощью уравнений состояний (3.4), (3.5) и указания значений начальных приращений факторов, проведен анализ динамики изменения факторов и их влияния на развитие системы показателей в целом.

Верификация разработанной когнитивной модели с целью проверки ее адекватности была проведена путем тестирования на ретроспективном периоде 2014–2020 гг. на основе имеющихся статистических данных по измеримым факторам модели. Для верификации использована разработанная методика верификации на основе критериального подхода, включающего решение задачи уменьшения или блокировки рисков снижения достоверности и точности получаемых результатов путем расчета и интерпретации системных характеристик когнитивной карты. Результаты применения методики позволили сделать вывод об адекватности разработанной когнитивной модели. Общая корректность модели на этом этапе подтвердилась близостью рассчитанных на модели темпов прироста факторов к действительным темпам прироста.

Задача управления считается решенной, если в условиях заданных ограничений найден сценарий планирования приращения значений функционала и индикаторов до целевых значений за счет импульсных воздействии (приращений значений факторов), обеспечивающий гарантированное достижение поставленной цели.

Последовательно задаваемые в ходе имитационного моделирования управляемого развития системы показатели «слабые» приращения значений латентных факторов на уровне 10%, позволили оценить чувствительность целевого показателя (рейтингового функционала) к управляющим воздействиям на выявленные латентные факторы по данным направлениям регулирования (табл. 3).

С учетом полученных предварительных результатов вычислительного эксперимента в ходе сценарного моделирования были рассчитаны требуемые интенсивности воздействия на управляющие факторы в процентном отношении при заданном приращении целевого фактора.

Таблица 3

Номер эксперимента	Управляемый фактор	Начальное значение	Импульс изменения	Изменение рейтингового функционала
1	<i>F1</i>	0,593	0,01	0,091
2	<i>F2</i>	0,194	0,02	0,078
...
24	<i>F24</i>	0,325	0,01	0,032

Задача решалась в условиях заданных ограничений на ресурсы, выделяемые на обеспечение приращения латентных факторов, в рамках которых был выбран наиболее предпочтительный вариант сценарного прогнозирования, минимизирующий расходы на их приращения.

4. Обсуждение. Интерпретация результатов численного эксперимента

С учетом реально достижимых значений латентных факторов на интервале 2020–2021 гг. выбран сценарий их приращения, представленный на рис. 2.

Наибольшая интенсивность воздействия потребовалась для следующих латентных факторов: Число публикаций в БД Scopus, WoS, Совместные научные проекты, Востребованность направлений подготовки, стимулирующие факторы, наименьшая – для следующих латентных факторов: Изменение структуры занятости НПП, Площади для образовательной деятельности, Доля НПП, планирующих строить интернациональную научную карьеру.



Рис. 2. Расчетные значения интенсивностей управляющих воздействий на латентные факторы в виде приращений в %, необходимые для достижения целевого прироста базовых показателей и функционала в 2021г.

Результаты расчета прогнозных значений показателей роста базовых показателей и функционала в 2021 г. с учетом выбранного сценария представлены на рис. 3. Полученные результаты сценарного прогнозирования показывают, что наибольший прирост получил показатель РР (репутация у работодателя) – 54%, а наименьший – ОСП – отношение числа студентов к числу преподавателей – 16%. Заданный прирост значений базовых показателей привел к увеличению значения функционала на 23%, что соответствует достижению его планового значения.




Рис. 3. Прогнозные значения роста базовых показателей и функционала в 2021г. по сравнению с 2020г. (2020г. -100%)

Сценарное прогнозирование развития ситуации позволило выбрать наиболее предпочтительный вариант, который в условиях заданных ограничений обеспечивает достижение требуемого планового значения целевого показателя при минимальных затратах ресурсов на приращение латентных факторов.

Результаты сценарного моделирования, представленные на рис. 2, с учетом реально достижимых значений латентных факторов на интервале 2020–2021 гг. соответствуют сценарию их приращения, обеспечивающему достижение требуемого значения целевого показателя (функционала). Таким, образом, цель исследования достигнута.

В результате выполненных расчетов можно сделать следующие выводы. Для гарантированного достижения значения функционала $F = 26,89$ к 2025 г., соответствующего 435 месту в рейтинге QS необходимо ступенчатое наращивание значений базовых показателей с учетом влияющих на них факторов, в интервале 2021–2025 гг. по следующей схеме.

В конце первого контрольного интервала (через 1 год) после уточнения актуальных значений базовых показателей и функционала в рейтинге QS провести оценку изменения влияния и взаимовлияния факторов на базовые показатели на основе методов факторного анализа, скорректировать данные, представленные в табл. 1, идентифицировать латентные факторы 3 – го уровня, актуализировать разработанную модель сценарного прогнозирования на основе когнитивной карты с учетом дополнительного (третьего) уровня латентных факторов, позволяющую построить адекватную и достоверную модель когнитивной карты, соответствующую текущему состоянию. На основе обновленной модели выполнить расчеты для обоснования набора новых импульсных воздействий на факторы 3-го, 2-го и 1-го уровней когнитивной модели на очередной период.

Заключение

В ходе выполнения исследования разработана итеративная обучаемая когнитивная модель сценарного прогнозирования мероприятий по достижению требуемых значений целевых показателей деятельности университета в международном институциональном рейтинге QS. На основе разработанной модели проведен расчет наиболее предпочтительного с точки зрения минимизации затрат варианта сценария набора требуемых интенсивностей воздействия на управляющие переменные (латентные факторы) при заданном плановом приращении значения целевого фактора.

Новизна предлагаемого подхода определяется использованием методов корреляционно-регрессионного и факторного анализа для определения силы взаимосвязей между латентными факторами, что обеспечило

идентификацию наиболее значимых латентных факторов при построении адекватной когнитивной модели. Предлагаемый подход позволяет обучать разработанную когнитивную модель путем корректировки структуры когнитивной карты и ее параметров по результатам актуализации исходных данных для ее построения.

В качестве направлений дальнейших исследований целесообразно решить задачу идентификации латентных факторов третьего уровня, что обеспечит повышение достоверности и точности когнитивной модели.

Список литературы

- [Авдеева и др. 2007] Авдеева З.К., Коврига С.В., Макаренко Д.И., Максимов В.И., Когнитивный подход в управлении // Пробл. управл. – 2007. – Вып. 3.
- [Беляев, 2007] Беляев В.И. Маркетинг: основы теории и практики: учеб. – 2-е изд., стереотип. – М.: КНОРУС, 2007.
- [Богомолова, 2004] Богомолова Е. В. SWOT-анализ: теория и практика применения // Экономический анализ: теория и практика. – 2004. – № 17 (32).
- [Болотова, 2012] Болотова Л.С. Системы искусственного интеллекта: модели и технологии, основанные на знаниях: учебник // ФГБОУ РГУИТП; ФГАУ ГНИИ ИТТ «Информатика». – М.: Финансы и статистика, 2012.
- [Борисов и др., 2021] Борисов В.В., Круглов В.В., Федулов А.С. Нечеткие модели и сети. – 2-е изд., стереотип. – Горячая линия – Телеком, 2021.
- [Горелова, 2019] Горелова Г.В. Когнитивные исследования сложных систем // Системный анализ в проектировании и управлении. – 2019. – Т. 23, № 3.
- [Горидько и др., 2017] Горидько Н.П., Нижегородцев Р.М. Современный экономический рост: теория и регрессионный анализ: монография. – М.: Инфра – М., 2017.
- [Дрейпер, 2019] Дрейпер Н. Прикладной регрессионный анализ. – М.: Вильямс И.Д., 2019.
- [Кизим, и др. 2011] Кизим Н.А., Хаустова В.Е. Особенности проверки моделей на основе когнитивных карт на устойчивость и достоверность // Современные подходы к моделированию сложных социально - экономических систем. – Х.: ФЛП Александрова К. М.; ИД «ИНЖЭК», 2011.
- [Корноушенко и др., 2000] Корноушенко Е.К., Максимов В.И. Управление ситуацией с использованием структурных свойств когнитивной карты // Тр. ИПУ РАН. – 2000. – Т. XI.
- [Кузнецов, 2005] Кузнецов О.П. Когнитивное моделирование слабоструктурированных ситуаций. [Электронный ресурс] <http://posp.raai.org/data/posp2005/Kuznetsov/kuznetsov.html> (дата обращения: 01.08.2022).
- [Кулинич, 2016] Кулинич А.А. Ситуационный, когнитивный и семиотический подходы к принятию решений в организациях // Открытое образование. – Т. 20. № 6. – 2016.

- [Кульба и др., 2002] Кульба В.В., Кононов Д.А., Ковалевский С.С. и др. Сценарный анализ динамики поведения социально-экономических систем. – М.: ИПУ РАН, 2002.
- [Максимов и др., 2004] Максимов В.И., Качаев С.В. Технологии информационного общества в действии: применение когнитивных методов в управлении бизнесом. [Электронный ресурс] http://www.rfbr.ru/default.asp?doc_id=5222 (дата обращения: 01.08.2022).
- [Максимов, 2005] Максимов В.И. Структурно-целевой анализ развития социально-экономических ситуаций // Проблемы управления. – 2005. – № 3.
- [Микрюков и др., 2020] Микрюков А.А., Гаспариан М.С., Карпов Д. С. Разработка предложений по продвижению университета в международном институциональном рейтинге QS на основе методов статистического анализа. Статистика и Экономика. – 2020. – 17 (1).
- [Робертс, 1986] Робертс Ф. С. Дискретные математические модели с приложениями к социальным, биологическим и экологическим задачам. – М.: Наука, 1986.
- [Соколов и др., 2016] Соколов Г.А., Сагиотов Р.В. Введение в регрессионный анализ и планирование регрессионных экспериментов в экономике: учебное пособие. – М.: Инфра-М, 2016.
- [Axelrod, 1976] Axelrod R. The Structure of Decision: Cognitive Maps of Political Elites. – Princeton. University Press, 1976.
- [Bodyanskiy at al., 2014] Bodyanskiy Yevgeniy V., Tyshchenko Oleksii K., Deineko Anastasia O. An Evolving Neuro-Fuzzy System with Online Learning/Self-learning // IJMecs. – 2014. – Vol. 7, No. 2. – Doi: 10.5815/ijmecs.2015.02.01.
- [Carvalho at al., 1999] Carvalho J.P. and Tom J.A.B. Rule Based Fuzzy Cognitive Maps - Fuzzy Causal Relations // Computational Intelligence for Modelling, Control and Automation: Evolutionary Computation & Fuzzy Logic for Intelligent Control, Knowledge Acquisition & Information Retrieval, edited by M. Mohammadi an, IOS Press, 1999.
- [Karabutov, 2020] Nikolay Karabutov. Structural Identifiability of Nonlinear Dynamic Systems under Uncertainty // International Journal of Intelligent Systems and Applications (IJISA). – 2020. – Vol.12, No. 1. – P. 12-22. – DOI: 10.5815/ijisa.2020.01.02.
- [Kosko, 1986] Kosko B., Fuzzy Cognitive Maps // International Journal of Man-Machine Studies. – 1986. No. 24.
- [Osoba at al., 2017] Osoba O.A., Kosko B. Fuzzy cognitive maps of public support for insurgency and terrorism // The Journal of Defense Modeling and Simulation. – Vol. 14, No. – 2017. – Doi: 10.1177/ 1548512916680779.
- [Salmeron at al., 2017] Salmeron J.L., Palos-Sanchez P.R. Uncertainty propagation in fuzzy grey cognitive maps with Hebbian-like learning algorithms // IEEE transactions on cybernetics. – 2017. – Vol. 49, No. 1.

ГИБРИДНЫЕ ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ ПЕРСОНАЛИЗИРОВАННОЙ ОЦЕНКИ СОСТОЯНИЯ СЛОЖНЫХ ОБЪЕКТОВ В МЕДИЦИНЕ С ПРИМЕНЕНИЕМ ДИНАМИЧЕСКОГО МОДЕЛИРОВАНИЯ ОБЪЕКТА ИССЛЕДОВАНИЯ

Румовская С.Б. (*sophiyabr@gmail.com*)

Калининградский филиал ФИЦ ИУ РАН, Калининград

В работе рассматриваются особенности проблемы оценки функций диагностируемых сложных объектов в медицине и риска развития их дефектов с целью постановки полного дифференциального диагноза и прогнозирования их состояния, а также предлагается разработать и исследовать методы и модели нового класса систем гибридного искусственного интеллекта для медицинской диагностики и прогнозирования. Подобные системы будут интегрировать разнородные знания: о процессе диагностики, о прогнозировании исходов и интерпретации прогноза выявленных дисфункций и патологий. Предлагается комбинировать модели: 1) функциональную и трансформационную гибридных интеллектуальных систем двух типов; 2) модель функционирования сложного объекта как гетерогенной биологической системы.

Ключевые слова: гибридная интеллектуальная система, динамическое моделирование, интеллектуальная система поддержки принятия решений, сложный объект диагностики, гетерогенная динамическая система, медицинская диагностика и прогнозирование.

Введение

Увеличивающиеся объем и разнообразие диагностической информации усложняют процессы мыслительной деятельности врачей и снижают эффективность мер здоровьесбережения. Этому также способствует низкий уровень поддержки персонализированной медицины информационными технологиями, в частности системами искусственного интеллекта. Особенно остро данное обстоятельство проявляется в лечебно-профилактических учреждениях амбулаторно-поликлинического типа в условиях дефицита времени приема пациента и врачей узкого профиля, особенно с большим опытом работы. При этом в России смертность от

основных неинфекционных заболеваний составляет 68,5% от общей смертности населения. От заболеваний поджелудочной железы, в частности от острого панкреатита (ОП) – до 15%, а при деструктивных формах – до 70% [Богданов и др., 2016; Клинические рекомендации, 2020; Стратегия, 2018]. ОП имеет разнообразную и зачастую непредсказуемую клиническую картину, пересекающуюся с рядом urgentных заболеваний органов брюшной полости. Превентивная диагностика, профилактика и персонализированная медицина, а также повышение уровня их поддержки информационными технологиями, в частности системами искусственного интеллекта, [Шляхто и др., 2021] могут привести к снижению вышеупомянутых показателей. Отсюда актуально: 1) исследование проблематики персонализированной оценки состояния (ПОС) сложного объекта (СО) в медицине как гетерогенной динамической системы; 2) разработка гибридных интеллектуальных систем (ГиИС) персонализированной диагностики и прогнозирования состояния организма человека (как СО). Подобные системы [Колесников и др., 2007] – междисциплинарного характера и комбинируют методы искусственного интеллекта различных классов. ГиИС отображают функциональную структуру решаемой проблемы и области её однородных параметров, представленных множеством однородных задач (ОЗ). Каждая ОЗ должна решаться специалистом(ами) соответствующей области медицинских знаний.

В работе рассмотрены особенности процессов и явлений выработки решений при ПОС СО. Также предлагается новое исследование, направленное на создание методов и моделей ГиИС для ПОС СО в медицине как гетерогенной динамической биологической системы (БС) – «Виртуальных консилиумов персонализированной диагностики и прогнозирования» (ВКПДП) на примере острого панкреатита. ВКПДП будут интегрировать разнородные модели выработки решений на разных этапах процесса персонализированной оценки состояния сложного объекта ситуативно в зависимости от выявленной симптоматики.

1. Персонализированная оценка состояния сложных объектов в медицине

Организм человека [Бельченко 2013; Гайворонский и др., 2018] – это сложная открытая целостная биологическая система:

- сложная – состоящая из множества разнородных элементов (органов, клеток, тканей, органоидов и молекул);
- открытая – существующая только благодаря непрерывному взаимодействию с окружающей средой (нет обмена – это смерть);
- биологическая – живая;
- система – состоящая из взаимосвязанных между собой элементов.

ПОС сложных объектов в медицине (организм пациента, его системы и подсистемы) включает две взаимосвязанные проблемы (рис. 1): 1) ранней полной дифференциальной диагностики и 2) прогнозирования исходов заболевания (с обоснованием). Точность диагноза влияет на достоверность прогноза. Ложно-отрицательные результаты приводят как к диагностическим, так и тактическим ошибкам, поскольку необходимо оценить состояние СО именно в фазе управляемости патологического процесса (рис. 1). Для подобных проблем характерны:

- гетерогенность – разнородность, разнообразие и возможная неспецифичность предикторов заболеваний в гетерогенном множестве всех показателей состояния здоровья, анализируемых при ПОС СО;
- полиморбидность [Ларина и др., 2019] – наличие нескольких заболеваний одновременно:
 - несвязанных – мультиморбидность – сопутствующие, конкурирующие и психические заболевания;
 - связанных – коморбидность – сопутствующие заболевания, связанные единым доказанным патогенетическим или генетическим механизмом. Могут как влиять, так и нет на прогноз.

Кроме того, есть болезни-хамелеоны, которые маскируются под другие, в том числе и очень далекие заболевания [Кобринский, 2016].

Все вышеуказанное влечет разнообразие направлений медицинских исследований пациента, изменяет и усложняет клиническую картину, а также процесс персонализированной оценки состояния сложного объекта.

Данные обстоятельства требуют участия коллектива специалистов различных профилей (рис. 1) в принятии диагностического решения. Это зачастую доступно только в стационарных больничных учреждениях. В то время, как в поликлиниках врачи (субъект диагностики на рис. 1) зачастую опираются только на международную классификацию болезней [МКБ, 2019], основанную на структурном анализе. Они мыслят, преимущественно отталкиваясь от таких понятий, как воспаления, гипо- и гипертрофии, опухоли и т.д. Последнее это дефекты (рис. 1) – патологические состояния или следствия заболеваний. В то время, как заболевание – один или несколько патологических процессов. Таким образом, в рассуждениях врачей поликлиник превалирует анатомо-морфологический анализ. Поэтому для повышения качества диагностических решений в рамках предлагаемого исследования (методы, подходы и этапы описаны в разделе 3) предполагается разработать виртуальный консилиум (как ГиИС), интегрирующий разнородные модели знаний о процессе диагностики и лечения на всех фазах заболевания (при фазовом протекании). Консилиум будет моделировать взаимодействие рассуждений в реальных коллективах врачей во главе с лицом, принимающим решения (ЛПР), привлекаемых к диагностике.

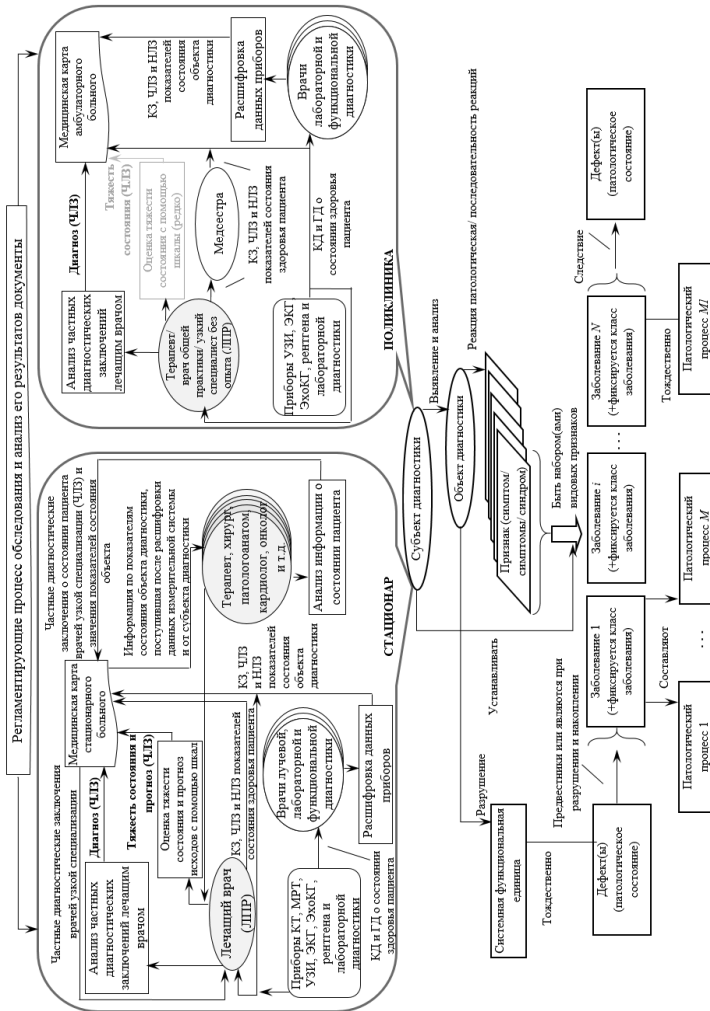


Рис. 1. Схема процесса оценки (диагностической и прогностической) состояния сложного объекта как гетерогенной системы в стационаре и в поликлинике: КЗ, ЧЛЗ, НЛЗ – количественные, четкие и нечеткие лингвистические значения, соответственно; КТ, МРТ – компьютерная и магнитно-резонансная томографии; УЗИ – ультразвуковое исследование; ЭКГ, ЭхоКГ – электро- и эхокардиография; КД и ГД – количественные и графические данные

Проблема прогнозирования (рис. 1) решается также ЛПП. Подходы к оценке и прогнозированию состояния больного, их достоинства и недостатки рассмотрены ниже в разделе 2. В том числе, и успешно (в сравнении с медицинскими шкалами) используемые активно за рубежом в последние 10 лет для решения подобных проблем искусственные нейронные сети (ИНС). В российской клинической медицине превалирует применение шкал. На базе опыта зарубежных коллег предлагается расширить ВК трансформационной ГиИС «нечеткая нейронная сеть ANFIS–экспертная система (ЭС)» (см. раздел 3). ANFIS позволит обеспечить формализацию размытых понятий и связей (нечеткость в рассуждениях врачей), вырабатывая прогноз, который будет интерпретироваться ЭС. Кроме того, при использовании нечеткой логики значительно снижается размер базы знаний, а также обучающей и тестирующей выборок. В случае отсутствия обоснования полное описание ситуации будет предоставлено ЛПП, который решает: пополнить базу знаний ЭС, либо получить прогноз заново на уточненных данных.

Также предлагается построить модель функционирования биологической системы – поджелудочной железы как подсистемы эндокринной и пищеварительной систем. Результаты работы данной модели будут передаваться моделям гетерогенного модельного поля (ГМП) ВК, вырабатывающим решение о состоянии организма пациента и его будущих возможных состояниях (раздел 3 данной работы). Динамическая модель в сочетании с интегрированными моделями (функциональной и трансформационной) выработки диагностических и прогнозных решений на всем протяжении процесса обследования предоставит возможность:

- построить полную траекторию патогенеза заболевания,
- определить прогноз его состояния
- и (в перспективе) начать лечение в то время, когда ещё нет явных структурных нарушений организма.

2. Подходы к оценке и прогнозированию состояния больного

Попытки диагностической и прогнозной оценки состояния больного начались в 50-х гг. XX века. Шкала Апгар [Calmes, 2015] – первый результат, базировавшийся на подсчете количественного критерия по выбранной шкале или таблице. Это легло в основу всех разработанных впоследствии тестов оценки степени тяжести заболевания, требований к лечению, эффективности терапии и прогноза развития исходов заболеваний пациентов как для контроля, так и в научно-исследовательских целях, например, в [Cullen et al., 1974; Knaus et al., 1985]. Всего более 100 шкал и их модификаций. Идеальный прогностический тест должен быть одновременно высокочувствительным (доля больных с положительным ре-

зультатом теста) и высокоспецифичным (доля здоровых с отрицательным результатом теста). Однако на практике в среднем прогностическая точность составляет 80–85%, а для острых хирургических заболеваний брюшной полости эти инструменты хорошо позволяют исключить тяжелое заболевание (хорошая отрицательная прогностическая ценность), однако положительная прогностическая ценность – около 40–60 %. Также многие шкалы дают хорошие оценки спустя 72 часа после поступления пациента, что не подходит для ранней диагностики, которая весьма актуальна для многих заболеваний, в частности для заболеваний поджелудочной железы, рак которой зачастую диагностируется на поздних стадиях, что становится фатальным для пациента в течении 5 лет, а острый панкреатит в 20–30% поздней диагностики приводит к осложнениям и также высокой летальности – до 70% от деструктивных форм [Богданов и др., 2016; Клинические рекомендации, 2020; Стратегия, 2018]. В обзоре [Dutta, 2022] по прогнозированию осложнений ОП лучшие показатели были у моделей, разработанных на базе ИНС и XGBoost (eXtreme Gradient Boosting).

Развитие теории биологических систем подстегнуло активное применение в медицине и биологии, в частности для решения задач прогнозирования:

- математического моделирования и аналитических методов [Койчубеков и др., 2014; Малиновский, 1984],
- методов теории вероятности и математической статистики (регрессионные и авторегрессионные модели, поточечные оценки, динамические баесовские сети, корреляционно-регрессионный анализ, методология марковских цепей, факторный, дискриминантный и кластерный анализ) [Киселев и др., 2010; Burkom et al., 2007; Moriña et al., 2011; Unkel, 2012].

В 90-х гг. прошлого века активно стало развиваться направление поддержки принятия решений при прогнозировании, диагностике и составлении плана лечения на основе искусственных нейронных сетей, в том числе относительно острого панкреатита [Литвин и др., 2012; Andersson et al., 2011; Hong et al., 2013]. Также встречаются исследования, в рамках которых прогноз ставился с помощью метода аналогий (рассуждения с помощью прецедентов) [Schmidt et al., 2007; Viboud et al., 2003]. В области оценки и прогнозирования состояния объектов в медицине в последние 5 лет ведутся работы в:

- P.L.A. Research Institute of General Surgery, Nanjing, Китай (ИНС для прогнозирования риска тяжелого ОП, связанного с острым повреждением легких [Fei et al., 2018]);
- Первом МГМУ им. И.М. Сеченова (системный подход и системный анализ в медицине и биологии) [Овсянников, 2019];

- ГБОУ ВПО Саратовский ГМУ им. В.И. Разумовского Минздрава России (статистический подход к решению практических проблем в медицине [Семенова, 2014]);
- Уфимский государственный авиационный технический университет совместно с Башкирским государственным медицинским университетом, Уфа, Россия (рекуррентные прогнозные нейронные сети [Хасанов и др., 2020]);
- Пензенский государственный университет совместно с Липецким государственным техническим университетом, Пенза-Липецк, Россия (многоуровневые нейронные сети с модульным представлением для задач прогнозирования и классификации [Герашенко и др., 2019]);
- Sun Yat-Sen University, Гуанчжоу, Китай (ИНС для выявления пациентов с рецидивирующим язвенным кровотечением [Wong et al., 2019]);
- Assistance Publique–Hôpitaux de Paris совместно с Institut national de recherche en informatique et en automatique INRIA и SNIPS, Париж, Франция (ИНС предлагается использовать для разработки лечения пациента исходя из предыдущих записей в его медицинской карте, а также предлагать возможные сценарии и учитывать риски [Escudié, 2018]);
- исследование применения различных моделей машинного обучения для задач прогнозирования в медицине. В последние два года в работах лучшие показатели прогнозирования у моделей, разработанных на базе XGBoost (eXtreme Gradient Boosting) в сочетании с SHAP (SHapley Additive exPlanations) – работы ученых Венгрии, Китая и США, например: Centre for Translational Medicine, Semmelweis University, Budapest, Hungary; Hospitals of Soochow University, Suzhou, China; Dascena, Inc, Houston, TX, United States [Kui et al., 2022; Yin, 2022; Thapa, 2022]; и другие.

Преимущества современных подходов к оценке и прогнозированию в медицине: 1) разнообразие тестов, а также наличие нозоспецифических шкал; 2) от клеточного уровня до уровня популяций с помощью матмоделирования, статистического и вероятностного моделирования, а также с помощью адаптивных методов решаются сложные проблемы в области эволюции, строения и развития организма, анализа заболеваний, здравоохранения.

Однако можно выделить следующие проблемы: 1) слишком большое количество тестов, отсутствие одной универсальной шкалы для оценки состояния сложного объекта в медицине; 2) статистические и вероятностные методы требуют описания множества однородных объектов по неко-

тому числу признаков, а также применяются преимущественно только для краткосрочного прогнозирования; 3) с помощью поточечных оценок (point-to-point linear estimates) можно строить только грубые прогнозы [Кондратьев, 2013]; 4) хотя ИНС и XGBoosting себя очень хорошо зарекомендовали для решения различных задач в медицине и здравоохранении, их решения не прозрачны и не позволяют учитывать все типы переменных, которыми оперируют врачи в своих рассуждениях, в частности нечеткость, которая имеет место как на множествах признаков и нозологических форм, так и при установлении соответствия их определенному классу болезней [Кобринский, 2016]; 5) для обучения ИНС нужна большая выборка.

3. Предлагаемые для исследования методы и подходы

Предлагается использовать проблемно-структурную методологию (ПС-методологию) разработки функциональных гибридных интеллектуальных систем Калининградского филиала Федерального исследовательского центра «Информатика и управление» РАН [Колесников и др., 2007] релевантную:

- разнообразию и растущему объему симптоматической информации, а также информации об этиологии и патогенезе заболеваний;
- гетерогенности проблем персонализированной оценки состояния сложных объектов в медицине, в частности,

ПС-методология сочетает методы анализа проблемы с динамическим синтезом ее декомпозированного представления и метода ее решения.

Предлагаемое исследование состоит из:

- четырех этапов системного анализа явлений и процессов персонализированной оценки состояния сложных объектов в медицине;
- и четырех этапов синтеза и тестирования искусственной гетерогенной медицинской интеллектуальной системы для диагностики и прогнозирования состояния сложных объектов (рис. 2) – ВКПДП на примере острого панкреатита как ГиИС.

Системный анализ проблемы ПОС СО включает следующие этапы:

- идентификация проблемы относительно ОП и анализ работы диагностируемой биологической системы (СО) – поджелудочной железы как биологической подсистемы эндокринной и пищеварительной систем;
- редукция взаимосвязанных проблем ранней полной дифференциальной диагностики ОП и прогнозирования его исходов с обоснованием прогноза в множество функциональных задач, составляющих функциональные структуры проблем, и технологических – для эффективной организации обработки данных и знаний;

- спецификация функциональных и технологических задач ПОС из полученной декомпозиции. Результат – концептуальные (функциональные, информационные и динамические) модели;
- выбор методов автоматизированного решения задач из декомпозиции проблем ПОС из множества классов базисных методов (аналитические, статистические, методы нечетких систем, логико-лингвистические, искусственных нейронных сетей, ансамблевые методы, эволюционные, методы рассуждения на основе опыта). Для задач формирования прогноза и его интерпретации уже определены классы методов – нейро-нечеткие и логико-лингвистические соответственно будут сравниваться с ансамблевыми методами в сочетании с SHAP [Kui et al., 2022].



Рис. 2. Общая схема моделей виртуальных консилиумов персонализированной диагностики и прогнозирования и их место в процессе персонализированной оценки состояния сложного объекта в медицине: ГиИС – гибридная интеллектуальная система; \longrightarrow – передача входной-выходной информации; $\longleftarrow \longrightarrow$ – инициализация и запуск функциональной/трансформационной модели; $\longrightarrow \longleftarrow$ – запрос на уточнение входной информации; \longrightarrow – переход к следующему этапу и передача всей полученной на предыдущих этапах входной и выходной информации; \square – интерфейсы ввода/вывода информации с возможностью корректировки

Синтез и тестирование ВКПДП предполагает:

- разработку моделей гетерогенного модельного поля для автоматизированного решения задач из декомпозиции ПОС СО;
- разработку эвристического алгоритма синтеза метода автоматизированной персонализированной оценки состояния сложного объекта. На вход алгоритма может быть подано разное подмножество моделей из ГМП. Например, для обработки данных анамнеза и результатов физикального обследования не нужны все модели ГМП: в частности, модель выработки решения кардиологом, который нужен только после получения результатов двух следующих этапов обследования. Кардиолог может вообще не понадобиться, если у больного нет сердечно-сосудистых заболеваний в анамнезе и не выявлены их симптомы при обследовании;
- разработку динамической модели биологической системы (СО) – поджелудочной железы как подсистемы эндокринной и пищеварительной систем;
- синтез метода ПОС с учетом разработанной динамической модели – инициализация функциональной структуры ГиИС для автоматизированной персонализированной оценки состояния сложного объекта с помощью разработанного на предыдущем этапе алгоритма;
- машинные эксперименты и интерпретация результатов.

При разработке ВКПДП как ГиИС за основу предлагается взять модель крупнозернистой функциональной ГиИС А.В. Колесникова–И.А. Кирикова и расширить её трансформационной моделью ГиИС. При разработке будут определяться множества элементов ВКПДП, отношения функционирования ВКПДП и интеграции элементов. Элементами ВКПДП с помощью базисных методов ГиИС будут моделироваться:

- выработка индивидуальных решений задач проблемы ранней полной дифференциальной диагностики сложного объекта;
- выработка решения проблемы прогнозирования исходов выявленного заболевания с обоснованием прогноза будущих состояний сложного объекта диагностики – трансформационная модель;
- функционирование диагностируемой биологической системы, с которой взаимодействуют остальные элементы.

Входная информация ВКПДП (рис. 2) – история болезни и семейный анамнез, данные физикального, лабораторного и инструментального обследований. Выходная информация ВКПДП – развернутое заключение о состоянии сложного объекта диагностики, релевантное эпикризу, включающее прогноз его состояния.

На вход нейро-нечеткой модели будут подаваться значения показателей состояния здоровья. Результат, полученный от нейро-нечеткой модели, вместе с множеством значений показателей состояния здоровья будут передаваться на вход логико-лингвистической модели с продукционной базой экспертных знаний для интерпретации. Для прогнозирования исходов острого панкреатита также будет разработана модель на базе ансамблевого метода XGBoost в сочетании с SHAP [Kui B. et al., 2022]. Результаты работы моделей будут сравниваться.

При анализе ПОС сложного объекта предполагается использовать комбинацию методов системного анализа – методы структуризации (сетевые и матричные), системный подход к медицинским проблемам и организму Гайдеса М.А. [Гайдес, 2021] и методы последовательной формализации решаемой проблемы. Это позволит перейти к системным и функциональным категориям при рассмотрении СО, а также к рассмотрению всех уровней иерархии рассматриваемого процесса принятия решения при ПОС (в том числе выделить горизонтальные связи). Концептуальную модель как множество функциональных и информационных моделей предлагается разрабатывать с помощью технологий IDEF0, IDEF3 и DFD. Множество динамических моделей предлагается описать с помощью медицинского алгоритмического языка ДРАКОН [Паронджанов, 2017].

Структуру биологической системы предполагается представить в виде смешанной иерархической структуры (СИС) [Глушков, 1981] как с вертикальными связями разной силы, так и горизонтальными взаимодействиями между элементами (подсистемами) одного уровня. В узлах СИС будут располагаться системные функциональные единицы БС – различные клеточные и тканевые структуры. Моделировать горизонтальные связи предполагается в рамках подхода к представлению биологических систем одноранговых элементов как динамических сетей, в узлах которых располагаются блоки с обратной связью – dynamic network motifs [Cloutier et al., 2011]. Описывать взаимодействие участков СИС и работу СИС в целом предполагается с помощью аппарата дифференциальных уравнений. Модель сложной динамической системы на основе полученных данных о принимаемых лекарствах и по результатам лабораторной и инструментальной диагностик предоставляет моделям ГМП, вырабатывающим решение о диагнозе и прогноз, информацию о ее реакциях на воздействие внешней среды – окружающих систем, с которыми она взаимодействует, принятых лекарств и т.д.

Заключение

Предлагаемое в данной работе новое исследование направлено на организацию динамического ситуативного синтеза алгоритма выработки: 1) диагностических решений – выявление заболевания или предпосылок к нему, определение его формы, стадии и наличия осложнений); 2) прогнозов будущих состояний (исходов заболеваний) сложного объекта в медицине. СО исследования – гетерогенная биологическая система (её подсистемы). Также в рамках исследования предполагается разработать новый класс медицинских интеллектуальных систем – гибридные интеллектуальные системы персонализированной диагностики и прогнозирования состояния сложных объектов «Виртуальные консилиумы персонализированной диагностики и прогнозирования исходов». ВКПДП будут релевантны реальной ситуации обследования пациента. Подобные системы: во-первых, выведут процессы здоровьесбережения на новый уровень – своевременной ранней диагностики ввиду системного подхода к анализу и моделированию персонализированной оценки состояния СО; во-вторых, повысят качество диагностических решений и прогноза, а также, как следствие, плана лечения, ошибки в котором могут привести к фатальным результатам. Отдельные модели ВКПДП смогут быть использованы для автономного решения задач в медицине относительно рассматриваемого объекта исследования.

Список литературы

- [Бельченко, 2013] Бельченко Л.А. Основы физиологии человека и животных (Организм как целое): учеб. пособие. – Новосибирск: Новосиб. гос. ун-т., 2013.
- [Богданов и др., 2016] Богданов С.Н., Бабаев С.Ю., Стражнов А.В., Строганов А.Б., Митрофанова Н.Н., Мельников В.Л. Клинико-морфологическая классификация острого панкреатита и его осложнений // Известия высших учебных заведений. Поволжский регион. Медицинские науки. – 2016. – Т. 40, № 4.
- [Гайворонский и др., 2018] Гайворонский И.В., Ничипорук Г.И., Гайворонский А.И. Анатомия человека: учебник в 2 т. / Под ред. И.В. Гайворонского. – М.: ГЭОТАР-Медиа, 2018.
- [Гайдес, 2021] Гайдес М.А. Общая Теория Систем. Антропологическая космоконцепция. Системный анализ происхождения и эволюции Вселенной. Книга 1. – СПб: SUPER Издательство, 2021.
- [Герашенко и др., 2019] Герашенко С.И., Астафьев А.Н. и др. Применение многоуровневых нейронных сетей для классификации биомедицинских данных // Вести высших учебных заведений Черноземья. – 2019. – № 3 (57).
- [Глушков, 1981] Глушков В.М., Валах В.Я. Что такое ОГАС? – М.: Наука, 1981.

- [Киселев и др., 2010] Киселев О.И., Маринич И.Г., Карпова Л.С. и др. Методика расчета эпидемических порогов по гриппу и острым респираторным вирусным инфекциям по субъектам Российской Федерации. – М.: НИИ гриппа Северо-Западного отделения РАМН, 2010.
- [Клинические рекомендации, 2020] Клинические рекомендации. Острый панкреатит. – 2020 (20.04.2021). Утверждены Минздравом РФ. – http://disuria.ru/_ld/9/999_kr20K85mz.pdf.
- [Кобринский, 2016] Кобринский Б.А. Нечеткость в клинической медицине и необходимость ее отражения в экспертных системах // Врач и информационные технологии. – 2016. – № 5.
- [Койчубеков и др., 2014] Койчубеков Б.К., Сорокина М.А., Мхитарян К.Э. Математические методы прогнозирования в медицине // Успехи современного естествознания. – 2014. – № 4.
- [Кондратьев, 2013] Кондратьев М.А. Методы прогнозирования и модели распространения заболеваний // Компьютерные исследования и моделирование. – 2013. – Т. 5, № 5.
- [Колесников и др., 2007] Колесников А.В., Кириков И.А. Методология и технология решения сложных задач методами функциональных гибридных интеллектуальных систем. – М.: ИПИ РАН, 2007.
- [Ларина и др., 2019] Ларина В.Н., Самородская И.В., и др. Комплексная патология: терминология, оценка тяжести состояния пациентов и возможный подход к их ведению // Клиническая геронтология. – 2019. – Т. 25, № 1-2.
- [Литвин и др., 2012] Литвин А.А., Жариков О.Г., Ковалев В.А. Система поддержки принятия решений в прогнозировании и диагностике инфицированного панкреонекроза // Врач и информационные технологии. – 2012. – № 2. – Режим доступа: <http://idmz.ru/jurnali/vrach-i-informatsionnye-tehnologii/2012/2/sistema-podderzhki-priniatiia-reshenii-v-prognozirovanii-i-diagnostike-infitsirovannogo-pankreonekroza> (дата обращения: 24.04.2022).
- [Малиновский, 1984] Малиновский А.А. Значение общей теории систем в биологических науках // Системные исследования. Методологические проблемы. Ежегодник. – М.: Наука, 1984.
- [Мионов и др., 2011] Мионов П.И., Медведев О.И. и др. Прогнозирование течения и исходов тяжелого острого панкреатита // Фундаментальные исследования. – 2011. – № 10, Ч. 2. – Режим доступа: <http://www.fundamental-research.ru/ru/article/view?id=28803> (дата обращения: 29.04.2022).
- [МКБ-11, 2019] МКБ-11 (Международная классификация болезней 11 пересмотра) [Электронный ресурс]. – <https://icd11.ru/> (Дата обращения: 01.08.2022).
- [Овсянников, 2019] Овсянников Л.Л. Видовая продолжительность жизни как продукт эволюции // Труды Института системного анализа Российской академии наук. – 2019. – Т. 69, № 2.
- [Паронджанов, 2017] Паронджанов В.Д. Алгоритмическая клиническая медицина или Зачем врачу блок-схемы алгоритмов? / Предисловие члена-корр. РАН Г.В. Порядина. – М.: ДМК Пресс, 2017.
- [Семенова, 2014] Семенова О.С. Математическое моделирование в медицине // Бюллетень медицинских интернет-конференций. – 2014. – Т. 4, № 5.

- [**Стратегия, 2018**] Стратегия формирования здорового образа жизни населения, профилактики и контроля неинфекционных заболеваний на период до 2025 года (дата публикации: 25.01.2018). – <https://gnicpm.ru/wp-content/uploads/2020/01/strategyzoch-2025.pdf> (дата обращения: 24.04.2022).
- [**Хасанов и др., 2020**] Хасанов А.Г., Шайбаков Д.Г., Жернаков С.В. и др. Нейронные сети для прогнозирования динамики развития заболеваний // Креативная хирургия и онкология. – 2020. – Т. 10, № 3.
- [**Шляхто и др., 2021**] Шляхто Е.В., Конради А.О. Персонализированная медицина. История, современное состояние проблемы и перспективы внедрения // Российский журнал персонализированной медицины. – 2021. – Т. 1, № 1.
- [**Andersson et al., 2011**] Andersson B., Andersson R., Ohlsson M., Nilsson J. Prediction of severe acute pancreatitis at admission to hospital using artificial neural networks // *Pancreatology*. – 2011. – 11 (3).
- [**Burkom et al., 2007**] Burkom H.S., Murphy S.P., Shmueli G. Automated Time Series Forecasting for Biosurveillance // *Statistics in Medicine*. – 2007. – 26 (22).
- [**Calmes, 2015**] Calmes S.H. Dr. Virginia Apgar and the Apgar Score: How the Apgar Score Came to Be // *Anesthesia and Analgesia*. – 2015. – 120 (5).
- [**Cloutier et al., 2011**] Cloutier M., Wang E. Dynamic modeling and analysis of cancer cellular network motifs // *Integrative Biology*. – 2011. – 3 (7).
- [**Cullen et al., 1974**] Cullen D.J., Civetta J.M., Briggs B.A., Ferrara L.C. Therapeutic intervention scoring system: a method for quantitative comparison of patient care // *Crit. Care Med*. – 1974. – 2.
- [**Dutta, 2022**] Dutta A.K. Predicting severity of acute pancreatitis: Emerging role of artificial intelligence // *Clinical and Translational Discovery*. – 2022. – 2.
- [**Escudí, 2018**] Escudí J.-B. Deep Representation for Patient Visits from Electronic Health Records // [arXiv.org – e-print service](https://arxiv.org/e-print). – 2018. – URL: <https://arxiv.org/pdf/1803.09533.pdf> (дата обращения: 20.07.2022).
- [**Fei et al., 2018**] Fei Y., Gao K., Li W.Q. Artificial neural network algorithm model as powerful tool to predict acute lung injury following to severe acute pancreatitis // *Pancreatology*, – 2018. – 18 (8).
- [**Hong et al., 2013**] Hong W., Chen X.R., Jin S.Q., Huang Q.K., Zhu Q.H., Pan J.Y. Use of an artificial neural network to predict persistent organ failure in patients with acute pancreatitis // *Clinics (São Paulo, Brazil)*. – 2013. – 68 (1).
- [**Kazmierczak, 1993**] Kazmierczak S.C., Catrou P.G., Van Lente F. Diagnostic accuracy of pancreatic enzymes evaluated by use of multivariate data analysis // *Clinical Chemistry*. – 1993. – 39 (9).
- [**Knaus et al., 1985**] Knaus W.A., Draper E.A., et al. APACHE II: A severity of disease classification system // *Critical Care Medicine*. – 1985. – 13.
- [**Kui et al., 2022**] Kui B., Pinter J., Molontay R., et al. EASY-APP: An artificial intelligence model and application for early and easy prediction of severity in acute pancreatitis // *Clinical and Translational Medicine*. – 2022. – 12.
- [**Moriña et al., 2011**] Moriña D., Puig P., Ríos J., Vilella A., Trilla A. A statistical model for hospital admissions caused by seasonal diseases // *Statistics in Medicine*. – 2011. – 30 (26).

- [Schmidt et al., 2007]** Schmidt R., Waligora T. Influenza Forecast: Case-Based Reasoning or Statistics? // Proceedings of the 11th international conference on Knowledge-Based Intelligent Information and Engineering Systems: Part I. Series: Lecture Notes in Computer Science. – 2007. – 4692.
- [Thapa et al., 2022]** Thapa R., Iqbal Z., Garikipati A. et al. Early prediction of severe acute pancreatitis using machine learning // *Pancreatology*. – 2022. – 22 (1).
- [Unkel, 2012]** Unkel S., Farrington C.P., Garthwaite P.H., et al. Statistical methods for the prospective detection of infectious disease outbreaks: a review // *Journal of the Royal Statistical Society: Series A (Statistics in Society)*. – 2012. – 175 (1).
- [Viboud et al., 2003]** Viboud C., Boëlle P.Y., Carrat F., Valleron A.J., Flahault A. Prediction of the Spread of Influenza Epidemics by the Method of Analogues // *American Journal of Epidemiology*. – 2003. – 158 (10).
- [Wong et al., 2019]** Wong G. L.-H., Ma A.J., Deng H., et al. Machine learning model to predict recurrent ulcer bleeding in patients with history of idiopathic gastroduodenal ulcer bleeding // *Alimentary Pharmacology and Therapeutics*. – 2019. – 49 (7).
- [Yin et al., 2022]** Yin M., Zhang R., Zhou Z., et al. Automated Machine Learning for the Early Prediction of the Severity of Acute Pancreatitis in Hospitals // *Frontiers in Cellular and Infection Microbiology*. – 2022. – 12.

ПОДХОД К РЕАЛИЗАЦИИ СКВОЗНОЙ ВИЗУАЛЬНОЙ ПОДДЕРЖКИ ПРОЦЕССОВ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ ИНТЕЛЛЕКТУАЛЬНЫХ АВТОМАТИЗИРОВАННЫХ ОБУЧАЮЩИХ СИСТЕМ

В.А. Углев (*vauglev@sfu-kras.ru*)

Сибирский федеральный университет, Красноярск

Т.А. Гаврилова (*gavrilova@gsom.spbu.ru*)

Высшая школа менеджмента СПбГУ, Санкт-Петербург

В статье описан подход к поддержке процессов принятия методических решений и их объяснения в Intellectual Tutoring Systems (ITS), опирающийся на средства когнитивной визуализации. Отмечена важность проблематики Explainable Artificial Intelligence (XAI) в рамках автоматического анализа гипотез, касающихся интерпретации учебной ситуации. С целью объединения в рамках единой логики анализа структурного и функционального подхода, рассмотрены различные графические нотации. Для предложенной модели принятия решений показаны вертикальные (по различным масштабам охвата учебной ситуации) и горизонтальные (по различным аспектам анализа) переходы между уровнями принятия решений. За основу взято сочетание метода когнитивных карт диагностики знаний (ККДЗ, структурный аспект) и метода унифицированного графического воплощения активности (UGVA, функциональный аспект). Описаны этапы процесса наложения на инвариантные графические нотации данных из цифрового образовательного следа. Отмечена важность обеспечения изоморфности отображения параметров учебной ситуации при взаимном переключении между картами и образами. Для иллюстрации примеров из реального учебного процесса приведены визуализации ККДЗ и антропоморфных образов UGVA. Показано преимущество сквозной визуальной поддержки как самого процесса принятия решений, так и синтеза разъясняющих текстов. В заключении отмечены ограничения подхода и обозначены направления дальнейших исследований.

Ключевые слова: принятие решений, Intellectual Tutoring Systems, когнитивная визуализация, объяснение решений.

Введение и существующие подходы

Современное электронное учебное пространство формируется во многом благодаря системам с элементами искусственного интеллекта, называемым интеллектуальными обучающими системами или Intellectual Tutoring Systems (ITS). Такие системы должны не только анализировать учебную обстановку и принимать решения, но и форматировать обратную информационную связь с человеком-пользователем (в основном с обучающимся и с учителем). Это важно в связи с тем, что человек склонен не доверять решениям систем, построенных на базе искусственного интеллекта, и нуждается в возможности убедиться в адекватности их реакций (концепция ХАИ [Arrieta 2020]).

Данные, которыми оперирует ITS, относятся к электронному курсу, к параметрам и действиям учащегося (digital footprint), а также к внесенной в обучающую систему базе знаний. Взяв за основу системный подход [Тарасенко 2017, Kossiakoff 2011], процедура анализа должна осуществляться одновременно в функциональном и структурном аспектах. При этом обработка учебной ситуации должна по возможности охватывать следующие типы параметров (подробнее см. в [Uglev 2022b]):

- масштаб принятия решений (P^M : нано, микро, мезо, макро, мета с рис. 1,а);
- уровни принятия решений (P^L : оперативный, тактический, стратегический);
- аспекты рассмотрения (P^K : предметный, компетентностный, нормативный, целевой);
- временную динамику (P^N : ретроспективные данные, текущие показатели, плановые/прогнозные показатели).

Связи между структурными компонентами учебного материала при освоении очередной ступени образования, организованными в виде совокупности учебных дисциплин, имеют группировку не только по семестрам (см. пример дерева специальности на рис. 1,б), но и соответствуют различным ведущим функциональным аспектам (ведущие группы ключевых умений, выделенных на основании компетентностной модели, на рисунке закодированы различными цветами). Примечательно, что связи в иерархии нелинейны и не позволяют однозначно соотнести профили дисциплин с группами компетенций или ключевых умений (это связь много-многим). На этом основании локальные выводы ITS, которые затрагивают текущую учебную ситуацию, должны либо учитывать неоднозначность этих связей, либо должны отталкиваться от стратегических целей работы с учебным материалом. Такой подход, с одной стороны, усложняет процесс принятия решений, а с другой – повышает его гибкость как в плане действий, так и в плане синтеза поясняющих решений.

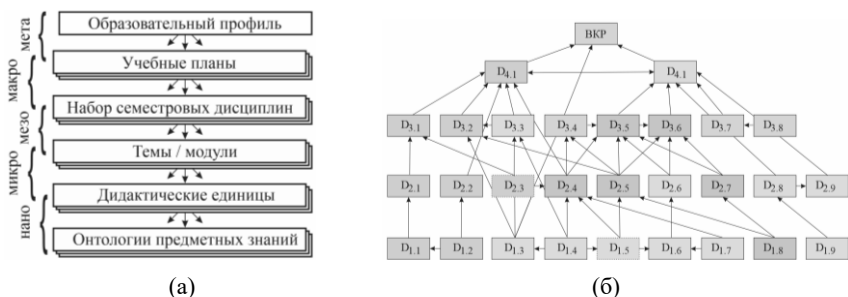


Рис. 1. Масштабы принятия решений относительно учебного материала (а) и структурная иерархия учебного материала с макроуровня (б), на примере учебной программы магистратуры направления «Информатика и вычислительная техника»)

Интерпретация решений ITS в доступной для человека форме, как правило, сводится к синтезу текста в естественно-языковой форме (текст диалога или его озвучивание виртуальным ассистентом) или в виде графического образа. Если предмет объяснения прост, то он хорошо воспринимается на слух. В противном случае требуется вывод большого объема текста и/или формирование поясняющих изображений [Grann 2014, Takada 2020]. Образовательные программы, электронные курсы и даже цифровой образовательный след учащегося – все они достаточно сложны как в структурном, так и в функциональном аспекте. Поэтому доступная аргументация действий ITS должна обеспечивать диалектическое единство (по Платону) формы и содержания.

Существующие различные подходы к организации структуры описания и логики анализа учебной ситуации, в основе которых лежит:

- онтология предметной области (например, [Zouir 2021]);
- куррикулулы и стандарты направлений подготовки (например, [Зыкина 2018]);
- модели отдельных курсов (например, [Бронов 2014]);
- модели экспертных систем (например, [Рыбина 2023]).

Учебный процесс, как и любой процесс, необходимо анализировать в динамике. Для этого необходимо учитывать динамику развития событий (прошлое), текущие параметры (настоящее) и прогнозируемые/плановые (будущее). Такой постановке задачи соответствует процесс афферентного синтеза П.К. Анохина [Анохин 1975]. Разделяя и одновременно учитывая структурную и функциональную специфику отношений между сущностями-

ми, задействованными в учебном процессе, можно сравнить те графические нотации, которые применяются разработчиками современных ITS (см. табл. 1).

Таблица 1

Нотация	Комплексность отображения	Масштабируемость	Учет динамики	Переход структура/ функция
Графики [Strunge 2021]	-	-	V	-
Графы [Хакимова 2020]	V	V	-	-
Дашборды [Bodily 2017]	V	-	-	-
Ментальные и концептуальные карты [Подвесовский 2018]	V	~V	-	-
Когнитивные карты диагностики знаний [Uglev 2022a]	V	V	~V	~V
Семантические сети и онтологии [Gavrilova 2019]	V	~V	~V	~V
Карты факторного пространства [Зиновьев 2000]	V	V	-	-
Кластеры [Нап 2011]	V	-	-	-
Пиктографики (лица Чернова) [Chernoff 1973]	V	-	-	-
UGVA [Uglev 2021]	V	V	~V	~V

Как видно из таблицы, системно учитывать структурный и функциональный аспекты с помощью указанных нотаций затруднено, т.к. они опираются на различные типы параметров учебной ситуации. Из последнего столбца следует, что одной графической нотации для решения этой проблемы недостаточно. Кроме того, использование онтологий влечет необходимость в тотальной детализации описания предметной области,

что в реальных условиях образовательного процесса затруднительно. Для преодоления затруднения нужно оперировать минимальным набором нотаций, которые позволят ITS в автоматическом режиме изоморфно отображать структурный и функциональный аспекты учебной ситуации для произвольного сочетания значений анализируемых параметров из P .

Целью данной работы будет кратко описать идею сквозного подхода к графическому сопровождению процессов принятия индивидуализированных решений в ITS с помощью визуальных нотаций. Для этого опишем базовую модель организации данных для сквозного анализа учебной ситуации; опишем процесс изоморфного отображения структурного представления с помощью когнитивных карт диагностики знаний (СМКД) и функционального представления с помощью метода унифицированного графического воплощения активности (UGVA); приведем общую схему осуществления сквозного анализа с помощью этих графических нотаций; а также приведем ряд иллюстрирующих примеров.

1. Метод

Формализация процесса принятия решений предполагает определение исходных данных, подлежащих анализу. Объединим следующие данные:

- модель учебного материала (от отдельных тестов/заданий до учебной программы, имеющих структурное описание и привязку к деятельности к результатам), дополненной семантическими связями (S , соответствует рис. 1-б) и методическими целями (G_1);
- цифровой образовательный след учащегося в составе модели ученика, включая продекларированные учащимся предпочтения и цели (G_2), а также данные об индивидуальной траектории обучения в виде проколов его действий (R);
- событие, инициированное учащимся или ITS (E), которое требует не только принятия решения, но и диалог с учащимся.

Тогда модель принятия решений, как механизма афферентного синтеза [Анохин 1975], реализуемая интеллектуальным решателем ITS будет соответствовать (1).

$$F(\gamma, E, R \mid S) \rightarrow (P, G) \rightarrow \langle y, q_a \rangle, \quad (1)$$

где y – выбранное решение для текущей ситуации, а q – результирующее пояснение (включая элементы графического сопровождения), соответствующее обстановке P в момент времени γ . Параметр a зависит как от специфики учебной ситуации и параметров анализа P , определяемых с помощью механизма экспертных систем, и при синтезе q выражается в выборе акцента в пользу структурного или функционального аспекта визуального сопровождения.

Для пояснения основных этапов перехода от исходных данным к решениям обратимся к схеме с рис. 2. Буквами обозначены следующие этапы работы интеллектуального решателя по [Uglev 2014]: а – запрос, б – инициализация моделей, в – синтез шаблонов визуализации, г – статистическая концентрация, д – метрическая концентрация, е – семантическая концентрация, ж – логическая концентрация, з – реакция ITS, и – синтез диалога. Через $E(\gamma, q)$ обозначено событие, перехода между компонентами P (относительно множеств M, L, K и N), инициированное пользователем при развитии поясняющего диалога.




Рис. 2. Схема осуществления сквозного анализа учебной ситуации с применением средств когнитивной визуализации данных

Индивидуализация решения и пояснений достигается как за счет учета цифрового образовательного следа, так и оперирования целевыми показателями G в контексте наиболее актуальных сочетаний условий отображения в P .

Назначение графического сопровождения решений и ответов ITS – побудить учащегося к осознанному принятию (доверию) реакций и ответов системы, касающихся методической стороны образовательного процесса. Общая идея применения средств когнитивной визуализации заключается в том, что на инвариантную подложку структурного или функционального пространства анализируемых объектов в одном из масштабов из M накладывается информация из индивидуального цифрового образовательного следа так, чтобы её можно было легко интерпретировать относительно параметров L, K и N в соответствии с направлением развития диалога ($E(\gamma_1) \rightarrow E(\gamma_2) \dots$). Отображение текущих значений ключевых показателей кодируется через цвет (тепловая карта), а второстепенных через иные параметры (толщину линий, форму элементов, параметры надписей и пр.). Возможность в рамках одного образа объединить текущие, ретроспективные и целевые показатели позволяет применить отображение (1) с сопоставимой детализацией как относительно структурного, так и относительно функционального аспектов (эффект изоморфизма).

В качестве основы для структурного представления используем метод Когнитивных карт диагностики знаний (ККДЗ) [Uglev 2021], формирующего карту изучаемого материала для всех уровней масштаба от микро до макро (см. рис. 1) в виде модели «маленького мира» с семантическими связями. На рис. 3,а показан пример карты для учебного семестра специальности направления «Информатика и вычислительная техника» (в узлах размещены учебные модули, ребра-семантические зависимости) и наложение на неё данных из индивидуального цифрового образовательного следа в предметном (рис. 3,б) и компетентностном (на рис. 3,в приведен пример для компетенции УК-1 «Способен осуществлять критический анализ проблемных ситуаций на основе системного подхода, вырабатывать стратегию действий») аспектах. Детальное описание наложения данных и их интерпретации приведено в [Uglev 2021]. Здесь же отметим, что учащемуся выводится тот вариант карты (или её фрагмент), который соответствует наиболее значительному акценту в пояснении принятого ITS решения с возможностью перейти к E` в иных аспектах (включая изменение масштаба) [Uglev 2022a].

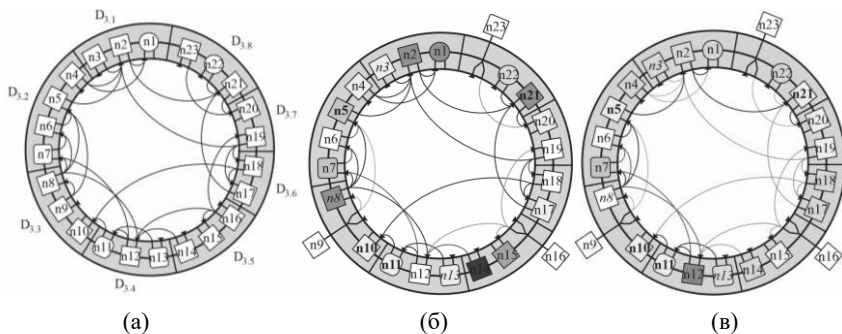


Рис. 3. Пример ККДЗ для учебных дисциплин одного семестра (а), наложение на карту данных одного из студентов в предметном (б), оценка успеваемости в баллах) и компетентностном (в), детализированная оценка уровня развития одной из компетентностей) аспектах

Основой для функционального представления станет нотация унифицированного графического воплощения активности (Unified Graphic Visualization of Activity, далее UGVA), формирующая образ деятельностного описания учебного процесса для всех уровней масштаба (см. рис. 1) в виде антропоморфного образа [Углев 2021], развивающего идею модуля Тризкина [Филимонов 2021]. На рис. 4,а показан пример образа для

учебного плана специальности направления «Информатика и вычислительная техника» (линейные размеры каждого блока – значение вклада каждой группы ключевых умений в базовом и вариативном развитии для текущей ступени образования в соответствии с цветами с рис. 1,б). При наложении на образ данных из цифрового образовательного следа выбранного нами студента получим изображения в предметном (рис. 4,б) и компетентностном (рис. 4,в) аспектах. Три ноги советуют рукам и туловищу (горизонтальная билатеральная симметрия, тип λBit), относительно аналогичных показателей для предыдущей ступени образования. Детальное описание наложения данных и их интерпретации приведено в [Углев 2022]. По аналогии с ККДЗ, образ интерактивен и позволяет через диалог получить изображения в контексте различных акцентов из P .

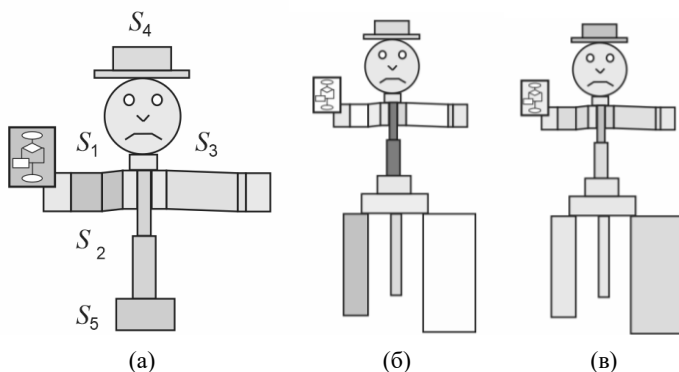


Рис. 4. Пример образа в нотации UGVA для учебного плана специальности направления «Информатика и вычислительная техника» (а), наложение на образ данных одного из студентов в предметном (б), оценка успеваемости в баллах) и компетентностном (в), надпредметная оценка развития совокупности компетенций) аспектах

Графические нотации ККДЗ и UGVA синтезируются интеллектуальным ядром ITS автоматически и обладают свойством интерактивности.

Суть сквозного подхода заключается в том, что интеллектуальный решатель ITS в момент времени γ при событии E входит в пространство, заданное параметрами анализа P для актуального значения M . Инвариантные графические образы методов CMKD и UGVA специфицируются под текущие значения L , K и N , извлекая и группируя из цифрового образовательного следа (метрическая концентрация) необходимые для решения и его пояснения данные. Это даёт возможность производить не только автоматическое переключение (перерисовку) карт и образов между аспек-

тами отображена P (см. рис. 5,а), но и изменять масштаб в соответствии потребностями процесса анализа (см. рис. 5,б) [Uglev 2022b]. Так как визуализации являются интерактивными, то по ним пользователь может получить как пояснения и детализацию, так и выйти за пределы текущего «фокуса» рассмотрения для уяснения того, зачем и почему были приняты текущие решения в ITS.

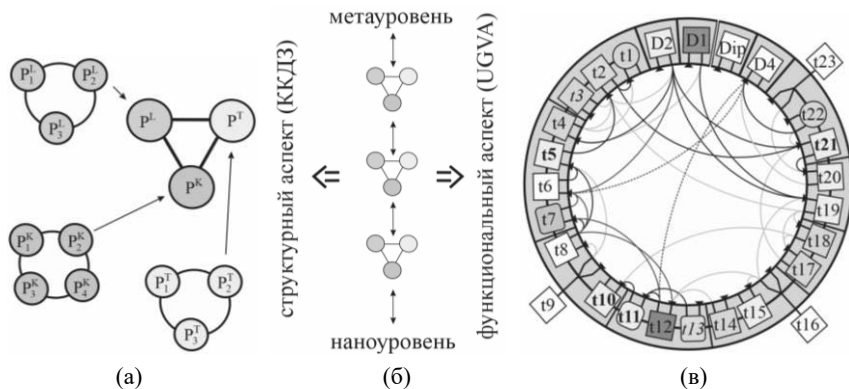


Рис. 5. Варибельность горизонтальных (а) и вертикальных (б) параметров синтеза образов при сквозном подходе к обеспечению процессов принятия и пояснения решений ITS; ККДЗ с дополнительными связями между уровнями (в)

Обеспечение гибкого перехода между визуализациями осуществляется за счёт свободного переключения как по вертикали (по масштабам из M), так и по горизонтали (по остальным компонентам P). Изоморфность отображения параметров цифрового следа в структурном и функциональном аспектах между нотациями может варьироваться относительно роли человека-получателя (учащийся, учитель, методист).

Сформировав и выведя карту/образ пользователю, автоматически формируется текст диалога. Он сопровождается набором уточняющих вопросов методического характера с параметрами, которые может выбрать человек-получатель. Направление диалога организуется как для разъяснения предпосылок (обратная стратегия вывода решателя), так и для разъяснения значимости (прямая стратегия вывода). При этом ККДЗ и образы UGVA могут выводиться лишь частично, повышая концентрацию наиболее значимых данных и акцентируя на них внимание пользователя (например, дополнительным цветовым выделением). Формируя соответствующий вариант запроса к ITS пользователь переходит к новому пояснению, сопровождаемому соответствующей визуализацией ($E \rightarrow E'$).

2. Пример применения и результаты

Рассмотрим примеры визуализации в привязке к реальному учебному процессу. В качестве базовой специальности выберем магистратуру Сибирского федерального университета по направлению «Информатика и вычислительная техника». Для текущего набора студентов (2021 год) дерево специальности будет выглядеть так, как показано на рис. 1,б (макро и мезо уровни). Каждой дисциплине D_j соответствует набор учебных тем (узлы t_i в графе), делящихся на дидактические единицы, укомплектованные контрольно-измерительным материалом. При формировании индивидуальной образовательной траектории отдельные элементы учебного материала (дидактические единицы, темы и даже целые учебные курсы) могут не включаться в программу подготовки (на ККДЗ отражаются на внешнем контуре круга)

В процессе обучения на базе ITS группа учащихся решает задания и тесты, которые оцениваются как на остаточные знания (предметный аспект), так и на уровень развития компетентностей. Эти данные дополняют индивидуальный цифровой образовательный след каждого студента и позволяют на конкретную дату запросить в ITS оценки и компетентностный профиль. Комбинируя текущие показатели, успехи за предыдущие контрольные точки и предпочтения учащегося (берутся из анкет), решатель ITS принимает решения (выставление оценки, выдача рекомендаций, прогнозирование динамики обучения, мотивация к интенсификации работы с учебным материалом и пр.), активизируя цепочку этапов с рис. 2.

Выберем в качестве объекта для иллюстрации результатов структурного представления одного из студентов. На рис. 3,б приведена ККДЗ для учебного материала с мезоуровня (третий учебный семестр), отражающего предметные оценки студента. Видно, что по результатам оценки заданий для предметных тем $t5$, $t7$, $t14$ и $t15$ имеет место недостаточное усвоение учебного материала. На рис. 3,в показана карта, соответствующая данным по компетенции УК-1 из его текущего надпредметного компетентностного профиля. По ней видно, что для успешного развития указанной компетенции необходимо подтянуть материал из предметных тем $t7$ и $t12$. Для принятия решений по синтезу подсказки в рамках дисциплины $D_{3.2}$ можно комбинировать данные с этих двух карт: отчетливо вырисовывается проблема учета межпредметных связей (на $t7$ влияет $t12$, которая зависит от $t14$). Если же учащийся, получивший рекомендация обратиться в первую очередь к $t14$ из $D_{3.5}$ и к $t5$, задаёт вопрос «Почему именно $t14$ и $t12$, а не $t7$?», получает выделение на карте с рис. 3,б семантических связей (красные стрелки), а также комментарии по поводу ранее указанных им предпочтений на овладение УК-1 по данным своей анкеты (в процессе диалога можно вывести карту с рис. 3,в по компетенциям и

указать красную стрелку $t7-t12$). Расширение глубины анализа можно добиться за счет вывода дополнительной информации о семантических связях за пределами текущего семестра. Например, на карте рис. 5, в дополнительно выведены данные о связях учебных тем семестра №3 с остальными уровнями иерархии с рис. 1,б (узлы D_1 , D_2 , D_4 и D_{ip}). Здесь красным дополнительно выделены те связи, которые позволяют усилить аргументацию в пользу изучения темы $t12$ относительно будущих учебных элементов (от $t6$ и $t12$ к D_4).

Теперь обратимся к данным этого же студента в функциональном аспекте на антропоморфных образах UGVA. На инвариантный образ специальности «Информатика и вычислительная техника» с рис. 4,а наложим оценки вклада значений оценок тех дисциплин, которые соответствуют каждой функциональной части образа (S). В качестве шкалы выбраны значения от красного (баллы стремятся к нулю) до зеленого (стремятся к 100), при зоне неопределённости в 50 (белый цвет). Например, предплечье правой руки (зона S_3) соответствует группе умений «Владеть математическими и алгоритмическими методами обработки информации» и проявлена с низкой результативностью (взвешенная оценка в 54.2 балла соответствует почти белому цвету с рис. 4,б). В компетентностном контексте (рис. 4,в) оценка уровня владения компетентностями составляет 37.3 баллов (если приводить коэффициент уверенности к баллам в интервале 0-100), что соответствует темно-розовому цвету (детальнее см. в [Uglev 2021]). При анализе проблемных моментов учебной ситуации с функциональной точки зрения следует указать на недостаточную развитость компетенций из зоны S_3 (базовая часть), пояснив студенту причины (включая аргументацию со структурного аспекта, представленного на ККДЗ выше).

Комбинируя карты и образы для различных аспектов формируется атлас, отражающий текущее состояние учебной ситуации, на основании которого можно ускорять проверку широкого круга гипотез в процессе работы ITS, так и пояснять соответствующие решения.

Ограничением предложенного подхода к визуализации для ITS является недостаточная выразительность ККДЗ и образов UGVA для масштабов наноуровня и метауровня (см. рис. 1,а). Наноуровень предполагает синтез диалога в предметной логике, а не в методической. В этой ситуации будет полезно использовать онтологический подход (например, как предложено в [Sychev 2020]). Работа же на метауровне в публикациях по ITS не имеет должной проработки и требует дополнительных исследований. В частности, данные об учащемся при переходе между ступенями образования выходят за рамки отдельно взятых обучающих систем и предполагают выработку и стандартизацию механизмов миграции цифрового образовательного следа между IT [Uglev 2020].

Заключение

Принятие методических решений механизмами Intellectual Tutoring Systems (ITS) нуждается в верифицируемых подходах как к выбору управляющего воздействия, так и к его разъяснению человеку. Без доверия между обучающей системой и учащимся не сформировать полноценного индивидуализированного учебного пространства. Поэтому исследования, касающиеся принятия решений механизмами ITS и их разъяснений, несомненно будут вызывать повышенный интерес у профильного сообщества. Предложенный нами сквозной подход, базирующийся на сочетании таких графических нотаций, как ККДЗ и UGVA, позволил получить практически полезные результаты. Их ещё предстоит тщательно проанализировать, показав влияние на результативность электронного учебного процесса в целом.

Текущими направлениями нашей работы по применению сквозного визуального сопровождения в учебном процессе является:

- мониторинг учебной ситуации магистрантов в течение всего периода обучения (от вступительных экзаменов до защиты дипломной работы);
- фиксация реакций учащихся на визуальное сопровождение рекомендаций системы и их разъяснения, а также оценка их влияния на изменение результативности учебного процесса;
- расширение номенклатуры специальностей для применения описанного подхода и сбор достаточного объёма экспериментальных данных.

Полученные в рамках данного исследования данные позволяют рассчитывать на то, что сквозное сопровождение процесса принятия решений и их объяснения может привести к значительному расширению возможностей ITS. Это должно способствовать повышению уровня доверия к решениям ITS в контексте концепции XAI. Так же предложенный подход может быть интегрирован в системы управления образовательными программами, использующие принцип сквозного мониторинга качества реализации учебного процесса с применением обучающих систем.

Список литературы

- [Arrieta, 2020] Arrieta A., Díaz-Rodríguez N., Del Ser et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI // Information fusion. – 2020. – Vol. 58.
- [Bodily, 2017] Bodily R., Verbert K. Review of research on student-facing learning analytics dashboards and educational recommender systems // IEEE Transactions on Learning Technologies. – 2017. – Vol. 10, No. 4.

- [**Chernoff, 1973**] Chernoff H. The use of faces to represent points in k-dimensional space graphically // Journal of the American Statistical Association. – 1973. – Vol. 68. – Doi: 10.1080/01621459.1973.10482434.
- [**Gavrilova, 2019**] Gavrilova T., Kokoulina L. Using Ontology Engineering to Design an Artificial Intelligence Course // Smart Education and e-Learning 2019. – Springer. 2019. – Doi: 10.1007/978-981-13-8260-4_19.
- [**Grann, 2014**] Grann J., Bushway D. Competency map: Visualizing student learning to promote student success // Proceedings of the fourth international conference on learning analytics and knowledge. – 2014.
- [**Han, 2011**] Han J., Kamber M., Pei J. Data Mining: Concepts and Techniques Third Edition // The Morgan Kaufmann Series in Data Management Systems. – 2011. – Vol. 5, No. 4.
- [**Kossiakoff, 2011**] Kossiakoff A. et al. Systems engineering principles and practice. – John Wiley & Sons, 2011. – Vol. 83.
- [**Strunge, 2021**] Strunge Mathiesen S., Schulz H. Aesthetics and Ordering in Stacked Area Charts // International Conference on Theory and Application of Diagrams. – Springer. 2021.
- [**Sychev, 2020**] Sychev O., Denisov M., Anikin A. Verifying algorithm traces and fault reason determining using ontology reasoning // CEUR Workshop Proceedings. – 2020.
- [**Takada, 2020**] Takada S., Cuadros-Vargas E., Impagliazzo J. et al. Toward the visual understanding of computing curricula // Education and Information Technologies. – 2020. – Vol. 25, No.5.
- [**Uglev, 2014**] Uglev V. Implementation of Decision-making Methods in Intelligent Automated Educational System Focused on Complete Individualization in Learning // AASRI Procedia. – 2014. – Vol. 6. – Doi: 10.1016/j.aasri.2014.05.010.
- [**Uglev, 2020**] Uglev V., Zacharyin K., Baryshev R. Cognitive Maps of Knowledge Diagnosis as an Element of a Digital Educational Footprint and a Copyright Object // Software Engineering Perspectives in Intelligent Systems. CoMeSySo 2020. Advances in Intelligent Systems and Computing. – 2020. – Vol. 1295. – Doi 10.1007/978-3-030-63319-6_31.
- [**Uglev, 2021**] Uglev V., Sychev O. Concentrating Competency Profile Data into Cognitive Map of Knowledge Diagnosis // International Conference on Theory and Application of Diagrams. – Springer, 2021. – Doi: 10.1007/978-3-030-86062-2_46.
- [**Uglev, 2022a**] Uglev V., Sychev O., Gavrilova T. Cross-cutting support of making and explaining decisions in Intelligent Tutoring Systems using Cognitive Maps of Knowledge Diagnosis // Intelligent Tutoring Systems. LNCS. – Springer. 2022. – Doi: 10.1007/978-3-031-09680-8_5.
- [**Uglev, 2022b**] Uglev V., Gavrilova T. Cross-Cutting Visual Support of Decision Making for Forming Personalized Learning Space // Novel & Intelligent Digital Systems: Proceedings of the 2nd International Conference (NiDS 2022). LNNS. – Vol. 556. – Springer, 2022. – Doi: 10.1007/978-3-031-17601-2_1.
- [**Zouri, 2021**] Zouri M., Ferworn A. An ontology-based approach for curriculum mapping in higher education // 2021 IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC). – IEEE6 2021.

- [Анохин, 1975] Анохин П.К. Очерки по физиологии функциональных систем. – Рипол Классик, 1975.
- [Бронов, 2014] Бронов С.А., Степанова Е.А., Калиновский К.В. и др. Автоматизированный анализ и синтез учебных планов вуза на основе массива дидактических единиц // Вестник Красноярского государственного аграрного университета. – 2014. – № 3.
- [Зиновьев, 2000] Зиновьев А.Ю., Питенко А.А. Визуализация произвольных данных методом упругих карт // Радиоэлектроника, информатика, управления. – 2000. – № 1 (3).
- [Зыкина, 2018] Зыкина А.В., Канева О.Н., Мунько В.В. The development of approaches for obtaining automated solution on the formation of the curriculum // Современные информационные технологии и ИТ-образование. – 2018. – Vol. 14, No. 4. – Doi: 10.25559/SITITO.14.201804.931-937.
- [Подвесовский, 2018] Подвесовский А.Г., Исаев Р.А. Метафоры визуализации нечетких когнитивных карт // Научная визуализация. – 2018. – Т.10, № 4.
- [Рыбина, 2023] Рыбина Г.В. Интеллектуальные обучающие системы на основе интегрированных экспертных систем: учебное пособие. – М.: Директ-Медиа, 2023. – URL: <https://biblioclub.ru/index.php?page=book&id=695260> (дата обращения: 25.08.2022).
- [Тарасенко, 2017] Тарасенко Ф.П. Прикладной системный анализ: учебник. – М: КНОРУС, 2017.
- [Углев, 2021] Углев В.А. Оценка баланса учебных планов при подготовке специалистов в области информационных технологий с применением метода UGVA // Современные информационные технологии и ИТ-образование. – 2021. – Т. 17, № 3. – URL: <http://sitito.cs.msu.ru/index.php/SITITO/article/view/777> (дата обращения: 25.08.2022).
- [Углев, 2022] Углев В.А. Визуальная поддержка принятия решений при синтезе учебных планов с помощью метода UGVA // Искусственный интеллект и принятие решений. – 2022. – № 2.
- [Филимонов 2021] Филимонов В.А. Способ когнитивной визуализации многопараметрических компонентов системы // Робототехника и искусственный интеллект: Материалы XIII Всероссийской конференции с международным участием. – Красноярск: Литера-принт, 2021. – URL: https://aesu.ru/local/conference/_docs/2021/RAI-21_print.pdf (дата обращения: 25.08.2022).
- [Хакимова, 2020] Хакимова А.Х., Золотарев О.В., Берберова М.А. Визуализация библиометрических сетей научных публикаций по вопросам исследования человеческого фактора при эксплуатации АЭС на основе библиографической базы данных Dimensions // Научная визуализация. – 2020. – Т. 12, № 2.

**СПОСОБ ОПТИМАЛЬНОГО УПРАВЛЕНИЯ
ТЕХНИЧЕСКОЙ СИСТЕМОЙ ИЛИ ПРОЦЕССОМ
С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВОЙ МОДЕЛИ
И АЛГОРИТМА ТОМПСОНОВСКОГО
СЭМПЛИРОВАНИЯ***

Л.С. Чернышев (*math4soft@yandex.ru*)
ООО «Матсофт», Москва

В работе предложен подход к решению задачи оптимального управления технической системой или процессом (объект управления) в виде определения набора значений управляющих параметров на установленном временном горизонте (горизонт управления), оптимизирующих целевую функцию объекта управления на данном горизонте. Для решения поставленной задачи разработан способ идентификации модели объекта управления с помощью искусственной нейронной сети (ИНС). Для каждого заданного временного среза требуемого горизонта управления, ИНС моделью рассчитываются прогнозные значения параметра состояния объекта на основе сгенерированных для каждого временного среза кортежей значений управляющего параметра объекта. Для каждого временного среза по сгенерированным кортежам управляющих параметров и рассчитанным прогнозом ИНС на их основе кортежам параметров состояния объекта рассчитываются кортежи целевой функции объекта. Решением задачи оптимального управления является выбор в процессе оптимизации одного значения управляющего параметра из сгенерированных кортежей для каждого временного среза. Выбранные для каждого временного среза значения управляющего параметра совместно обеспечивают оптимум суммы значений целевой функции по всем заданным временным срезам требуемого горизонта управления. Оптимизация целевой функции объекта проводится с использованием алгоритма Томпсоновского сэмплирования , применяемого в известной задаче о «Многоруком бандите». В качестве примера решена задача построения набора оптимальных

* Данная работа выполнена в рамках договора гранта от Фонда содействия инновациям 122ГС1ИИС12-D7/76682 от 09.06.2022.

цен на товар, реализация которого ведется на свободном рынке, максимизирующего прибыль предприятия- продавца для заданного горизонта управления.

Ключевые слова: нейросеть, временной ряд, прогнозирующая модель, Томпсоновское сэмплирование, задача о многоугольнике бандита, горизонт управления, управляющие параметры, параметры состояния, целевая функция, оптимизация, максимизация прибыли предприятия-продавца маркетплейса.

Введение

Функционирование любой технической системы, а также эволюция множества разнообразных процессов (далее Объект управления или просто Объект), связано с последовательным изменением значений параметров состояния, описывающих основные характеристики данного Объекта управления в данной точке фазового пространства. Для каждой такой точки фазового пространства существует ряд параметров, влияющих на Объект управления и приводящих к изменению его параметров состояния, которые будем называть параметрами управления или управляющими параметрами. В данной работе рассматриваются такие Объекты управления, у которых смена параметров состояния происходит по оси времени. Если объект управления подвержен влиянию стохастических факторов, то в большинстве случаев в каждый момент времени невозможно оценить степень влияния каждого из них, что делает задачу управления Объектом с целью получения определенного результата в будущем крайне сложной. Будем рассматривать Объект с одним главным параметром состояния и одним главным параметром управления. Учет влияния остальных, не поддающихся прямой оценке, параметров управления будет произведен за счет использования искусственной нейронной сети, моделирующей эволюцию Объекта управления на интервалах дискретности временной шкалы, используя только пары синхронных исторических наблюдений за динамикой главного параметра управления и динамикой основного параметра состояния системы. В работе рассматривается подход к решению задачи оптимизации целевой функции, зависящей от параметров Объекта, на моментах времени в будущем внутри временного горизонта управления. Для решения указанной задачи необходимо получить значения основных управляющих параметров на всех временных срезах, на которые делится горизонт управления, обеспечивающие оптимум (максимум или минимум) целевой функции на данном горизонте в условиях априорной неопределенности относительно всех влияющих на объект факторов. Для этого на первом этапе производится идентификация модели объекта

управления с использованием искусственной нейронной сети (ИНС), включающая выбор архитектуры ИНС, ее обучение и валидацию. На втором этапе для каждого временного среза горизонта управления рассчитываются кортежи значений целевой функции объекта управления. Для расчета значений целевой функции требуются значения управляющих параметров и параметров состояния объекта управления. Для каждого заданного временного среза требуемого горизонта управления, ИНС моделью рассчитываются прогнозные значения параметра состояния объекта на основе сгенерированных для каждого временного среза кортежей значений управляющего параметра объекта. Далее для каждого временного среза по сгенерированным кортежам управляющих параметров и рассчитанным на их основе с помощью прогнозирующей модели ИНС кортежам параметров состояния объекта, рассчитываются кортежи целевой функции объекта. Особенностью построенных кортежей прогнозных значений параметра состояния объекта, а вместе с ними и кортежей значений целевой функции, является их размерность (размерности кортежей целевой функции совпадают с размерностью кортежей параметров состояния), растущая с повышением порядкового номера временного среза горизонта управления как степенная функция с показателем степени, равным порядковому номеру временного среза. Например, если для каждого временного среза генерируется N_u значений управляющего параметра, то количество значений целевой функции, соответствующих всем вариантам комбинаций управляющих параметров для горизонта с номером t будет N_u в степени t . Если выбирать по одному значению управляющих параметров для каждого горизонта, то такому набору будет соответствовать набор значений целевой функции, при этом полное число различающихся между собой наборов целевой функции будет N_u в степени t .

На третьем этапе необходимо провести процедуру оптимизации, заключающуюся в выборе одного оптимального набора из значений целевой функции, описанных выше, который будет отвечать условию оптимума – т.е. иметь максимальную сумму при решении задачи максимизации или – минимальную сумму – при решении задачи минимизации. Оптимизация проводится с использованием модифицированного метода решения задачи «многорукого бандита» с использованием Томпсонского сэмплирования [Томпсон, У.Р., 1935], [Даниэль Дж. Руссо, 2018], [Ferreira K.J., 2015]. Классические методы нелинейной оптимизации, такие как градиентные методы оптимизации не эффективны для работы с результатами прогнозирования ИНС модели из-за высокой «овражности» полученных прогнозных данных. Задача «многорукого бандита» является одной из самых основных задач в науке о решениях стохастическим методом- задачи об оптимальном распределении ресурсов в условиях, когда нет воз-

возможности применять детерминированные методы оптимизации. Алгоритм Томпсонаовского сэмплирования с использованием множества бетта-распределений с корректируемыми на каждой итерации параметрами позволяет эффективно определить оптимальный набор параметров управления – по одному для каждого временного среза горизонта управления из ранее сгенерированных кортежей параметров управления для каждого временного среза горизонта управления. Выбранные в процессе оптимизации для каждого временного среза значения управляющего параметра совместно обеспечивают оптимум суммы значений целевой функции по всем заданным временным срезам требуемого горизонта управления.

1. Прогнозирование значений параметров состояния объекта

Постановка задачи идентификации ИНС модели объекта управления, а так же способ ее решения, подробно описаны в работах: [Чернышев Л.С., 2021], [Чернышев Л.С, 2022 а], [Чернышев Л.С, 2022 б], опирающиеся на классические работы по использованию аппарата нейронных сетей для прогнозирования значений временных рядов: [Хайкин С., 2006], [Галушкин А.И., 2000] и оптимального управления: [Егупов Н.Д., 2002], [Макаров И.М., 2006], [Пупков К.А., 1994], [Тимофеев А.В., 1994], [Терехов В.А., 1999]. Пусть t -индекс временного среза горизонта управления t_N : $t= 1.. N$, тогда прогнозирующая модель (ПМ) для первого временного среза ($t=1$) имеет развернутый вид:

$$Y_1(t, U_1) == f \left[\sum_{j=0}^G \left[f \left[\sum_{i=0}^{Kx-t} (bx_{i,j} \cdot dy(L - K + t + i)) + \sum_{i=0}^{Ku-t-1} (bu_{i,j} \cdot dp(L - K + t + i + 1)) + bb_j + bu_{Ku,j} \cdot U_1 \right] \cdot b2_j \right] + bb2 \right], \quad (1)$$

а для каждого последующего из временных срезов $t(t=2..N)$ горизонта управления t_N , ПМ (4) имеет развернутый вид:

$$Y_t(t, U_t, U_{t-1}, \dots, U_1, Y_{t-1}, \dots, Y_1) = \\ = f \left[\sum_{j=0}^G \left[f \left[\sum_{i=0}^{Kx-t} (bx_{i,j} \cdot dy(L - K + t + i)) + \sum_{i=0}^{Ku-t-1} (bu_{i,j} \cdot dp(L - K + t + i + 1)) + bb_j + \sum_{i=1}^{t-1} (bx_{Kx-t+i+1,j} \cdot Y_i) + \sum_{i=1}^{t-1} (bu_{Ku-t+i,j} \cdot U_i) + bu_{Ku,j} \cdot U_t \right] \cdot b2_j \right] + bb2 \right], \quad (2)$$

где для (1) и (2) f – функция активации – гиперболический тангенс; набор параметров ПМ, со ответствующих временному срезу синдексом t включает в себя применительно к (1) и (2): b_x, b_u -матрицы синаптических коэффициентов перехода на j -й нейрон скрытого слоя с нейронах входного слоя с номерами: от 0 до $Kx - 1$ и от Kx до $Kx + Ku - 1$ – соответственно для b_x и b_u ; $dy(t)$ – значения обучающего временного ряда параметров состояния Объекта, относящихся к интервалу временного ряда с индексом $=L - Kx + t + i$, при $i = 0..Kx - t$, $dp(t)$ – значения обучающего временного ряда управляющих параметров Объекта, относящихся к интервалу временного ряда с индексом $=L - Ku + t + i + 1$, при $i = 0..Ku - t - 1$; U_t – наборы значений управляющих параметров, соответствующих временному срезу t горизонта управления, представляющие из себя смоделированные наборы параметров управления объектом, имеющих заданную дискретность и ограничение на значения $U_{min_t} \leq U_t \leq U_{max_t}$ и по которым будет проводится оптимизация целевой функции объекта для временного среза t горизонта управления; Y_t -вектор, состоящий из набора прогнозных значений параметров состояния, вычисленных с использованием ПМ для предыдущих текущему временному срезу с индексом $t > 1$ временных срезов $t_i, i=(1..t-1)$ горизонта управления t_N ; таким образом, если на каждом временном срезе t модели по определенному алгоритму (например - равномерным распределением на отрезке) генерируется Nu_t значений управляющих параметров: $U_{min_t} \leq U_t \leq U_{max_t}$, то число всевозможных прогнозных значений параметров состояний Y_t для временного среза t будет соответствовать произведению $\prod_{i=1}^t Nu_i$, т.е. для случая, когда для каждого временного среза с индексом t генерируется одинаковое количество параметров управления $= Nu$, то число рассчитанных для каждого временного среза с индексом t значений Y_t будет возрастать пропорционально степени t с основанием Nu . Число возможных значений целевой функции $P_t = F(t, Y_t, U_t)$ для каждого временного среза с индексом t в свою очередь будет так же возрастать пропорционально степени t с основанием Nu .

2. Способ оптимизации по целевой функции объекта управления

После завершения процедуры идентификации прогнозирующей модели (ПМ) объекта управления, т.е. построения, обучения и верификации ИНС на обучающих рядах и рядах валидации, необходимо решить задачу нахождения такого набора значений управляющих параметров объекта управления U_t для каждого временного среза t установленного временного горизонта управления t_N , который доставляет оптимум целевой функ-

ции объекта управления по сумме ее значений для всех построенных временных срезов заданного горизонта управления. Например, если $P(t, \mathbf{U}_t, \mathbf{Y}_t)$ – целевая функция объекта, зависящая как от набора управляющих параметров, так и от набора параметров состояния объекта для каждого временного среза горизонта управления t_N где требуется ее максимизация, то решением задачи будет набор \mathbf{U}_t , состоящий из единственного оптимального значения управляющего параметра для каждого временного среза горизонта управления.

$$\langle \mathbf{U}_t \rangle = \text{Argmax}_{\mathbf{U}_t} (\sum_{t=0}^T P(t, \mathbf{U}_t, \mathbf{Y}_t)). \quad (3)$$

В качестве метода оптимизации для нахождения оптимального набора управляющих параметров $\langle \mathbf{U}_{opt_t} \rangle$, обеспечивающий оптимум набора значений целевой функции $\mathbf{P}_t = F(t, \mathbf{Y}_t, \mathbf{U}_t)$ в работе предложен модифицированный алгоритм Томпсоновского сэмплирования [Томпсон, У.Р., 1935], [Даниэль Дж. Руссо, 2018], [Ferreira K.J., 2015]. Согласно данному алгоритму генерируются наборы значений \mathbf{U}_t , в каждый из которых входят по одному выбранному алгоритмом значению U_t для каждого временного среза горизонта управления. Полученные наборы будут тестироваться на оптимальность, для чего согласно (1) для $t=1$ и согласно (2) для $t=2..N$ рассчитываются соответствующие значениям \mathbf{U}_t наборы значений \mathbf{Y}_t . Затем согласно заданной для данного объекта управления зависимости целевой функции $\mathbf{P}_t = F(t, \mathbf{Y}_t, \mathbf{U}_t)$ от управляющих параметров и параметров состояния рассчитываются наборы целевой функции \mathbf{P}_t , представляющие собой траектории в пространстве параметров U, Y, t .

На первом этапе оптимизации по предложенному алгоритму делят диапазон возможного изменения управляющего параметра объекта $[U_{min_t}, U_{max_t}]$ на некоторое число интервалов N_u . Ограничение на количество таких интервалов N_u накладывается производительностью оборудования. Если планируется совершить N_s операций выборочного тестирования полученных наборов целевой функции, то число N_u следует выбирать $\langle N_s/100$.

Одним из способов генерации набора \mathbf{U}_t может быть, см например [Чернышев Л.С, 2022 а], [Чернышев Л.С, 2022 б] таким,; набор значений параметра управления \mathbf{U}_t для последующих расчетов значений целевой функции генерируется таким образом, что его максимальная и минимальные границы выбираются по значениям среднего $U_{сред}$ и по значению стандартного среднеквадратического отклонения σ имеющегося временного ряда измеренных ранее значений управляющего параметра, исполь-

зую правило 3 сигма, что означает более чем 99% вероятность охвата всех возможных значений управляющего параметра при гауссовом распределении случайной величины его значений, т.е. $U_{min} = U_{сред} - 3 * \sigma$, $U_{max} = U_{сред} + 3 * \sigma$.

Затем случайным образом для каждого временного среза t горизонта управления разыгрывается индекс j_t показывающий из какого интервала допустимых значений $U_{min j,t} \leq U_t \leq U_{max j,t}$ будут выбраны значения управляющих параметров. Данный интервал значений в свою очередь делится на интервалы определенной дискретности и, с точностью до заданной дискретности, генератором случайных чисел генерируется значение управляющего параметра в границах выбранного интервала. Для каждого временного среза производится аналогичная операция. Набор значений U_t характеризует уникальную траекторию в пространстве возможных значений управляющего параметра, которая однозначно определит набор параметров состояния объекта и набор значений целевой функции P_t . Всего производится N_s таких генераций. Далее определяют локально оптимальную траекторию по набору P_t дающему максимальную сумму для всех временных срезов и фиксируют эту сумму как $M1$.

На втором этапе используется модификация алгоритма Томпсонавского семплирования. Для этого на первой итерации семплирования ($i=0$) каждому из N_u интервалов диапазона возможных значений U ставятся в соответствие одни и те же параметры бэта -распределения – α_0 и β_0 . Случайная величина X имеет бета-распределение: $X \sim B(\alpha, \beta)$

$$f_X(x) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} \quad (4)$$

$$B(\alpha, \beta) = \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx,$$

где $\alpha, \beta > 0$ произвольные фиксированные параметры.

Затем для каждого из $j=1..N_u$ интервалов для каждого временного среза t горизонта управления из (4) генерируется по одному случайному значению $f_{j,t}$, принадлежащих бэта –распределениям каждого j -го интервала. Максимальное из сгенерированных значений для каждого временного среза определит номер интервала $n_{0,t}$, (индекс 0 означает первую итерацию семплирования), из которого будет выбрано уже случайное - по закону равномерного распределения, из возможных дискретных значений, определенных на предыдущем этапе, значение $U_{min n_{0,t},t} \leq U_t \leq U_{max n_{0,t},t}$. Процедура повторится для каждого из временных срезов горизонта

управления. Полученные значения $U_{n_0,t}$ для каждого временного среза создадут новую траекторию в пространстве возможных значений управляющего параметра и индекса временного среза t . По построенной траектории согласно (1) и (2) рассчитываются траектории Y_t , затем P_t . Сумма P_t по данной траектории $U_{n_i,t}$ равная M_i сравнивается, например с $0.5 * M_1$, чтобы определить – получена удачная траектория или нет. Если траектория «удачная», т.е., например, $M_i > 0,5M_1$, то параметры бэ́та-распределений $\alpha_{j,t}$ и $\beta_{j,t}$ интервалов U , участвовавших в данной траектории для каждого временного среза получают «награду» в виде корректировки:

$$\alpha_{j,t}^{\wedge} = \alpha_{j,t} + \gamma, \beta_{j,t}^{\wedge} = \beta_{j,t} - \gamma, \quad (5)$$

где γ – параметр «награды» может быть выбран например как: $\gamma = 1/N_s$, где N_s – запланированное число строящихся траекторий на этом этапе. В работе [Ferreira K.J., 2015] параметр корректировки γ предлагается выбирать порядка $1/\sqrt{N_s * \log(N_s)}$. Таким образом, интервалы, участвовавшие в «успешной» траектории получают чуть большее преимущество перед остальными интервалами на следующей итерации сэмплирования, т.к. медиана их бэ́та-распределений сместится на малую величину вправо, что даст чуть более высокие шансы для этих интервалов выиграть при сравнении интервалов по случайным значениям, сгенерированным по бэ́та-распределениями этих интервалов в следующем раунде сэмплирования. Таким образом – интервалы, которые участвовали в построении наиболее результативных траекторий будут получать все большие и большие преимущества над остальными, что обеспечит при больших i – номерах итерации сэмплирования – более частую эксплуатацию наиболее эффективных диапазонов значений управляющего параметра для соответствующих временных срезов. В дальнейшем на следующем этапе можно отбросить абсолютно неэффективные интервалы на соответствующих временных срезах и начать новый этап – процедуру дробления только эффективных интервалов, внутри которых так же будут определяться свои лидеры. Процедуру можно продолжать вплоть до достижения лимита по количеству сэмплирований, связанного с ограничением на время расчетов. Локальным решением задачи оптимизации будет траектория, состоящая из набора U_t , для которой будет получена максимальная сумма набора P_t .

3. Результаты применения метода для оптимизации прибыли предприятия-продавца на маркетплейсе

В качестве примера решена задача построения набора оптимальных цен на товар, реализация которого ведется на свободном рынке, максимизирующего прибыль предприятия – продавца для горизонта управления в

36 дней (9 временных срезов с дискретностью 4 суток). В качестве обучающих рядов модели ИНС использовались – ряд количества ежедневных продаж $N(i)$ в качестве вектора параметров состояния торгового процесса и временной ряд ежедневного изменения цены $Price(i)$ – в качестве вектора управляющих параметров торгового процесса общей длиной 497 суток. Цена оказывает важное влияние на количество продаж, тем не менее есть много случайных факторов, так же влияющих на исследуемый зависимый параметр, прямое влияние которых оценить невозможно – например падение рейтинга товара в результате негативных отзывов, специально заказанных конкурентами, внезапное перенасыщение рынка данного товара и пр. Нейросетевой прогноз учитывает влияние этих факторов в будущем. Удачный прогноз получается для горизонтов прогнозирования порядка 10% от длины обучающей выборки.

Обучение и валидация полученного после обучения прогноза ИНС производилось согласно методам, описанным в [Чернышев Л.С, 2021], [Чернышев Л.С, 2022a], [Чернышев Л.С, 2022б] по обучающим временным рядам длиной 440 суток и рядам валидации длиной 57 суток.

На рис. 1,а показан результат процедуры обучения ИНС модели процесса реализации товара на начальном этапе, а на рис. 1,б) – после 1000 итераций обучения. Кривая 1 – динамика обучающего ряда параметра состояния объекта управления – числа продаж в сутки, Кривая 3 – динамика валидационного ряда параметра состояния объекта управления числа продаж в сутки, Кривая 2 – динамика обучающего и валидационного рядов управляющего параметра- среднесуточной цены.




Рис. 1,а




Рис. 1,б

Модель, полученная в результате обучения после 1000 циклов итерации признана прошедшей валидацию и годной для использования в следующей процедуре оптимизации. Синаптические коэффициенты дан-

ной модели будут использованы в формулах (1) и (2) для прогнозирования параметров состояния объекта управления – в нашем случае- для прогнозирования числа ежедневных продаж на временных срезах заданного горизонта управления.

Целевая функция объекта управления – в нашем случае – торгового процесса реализации товара на свободном рынке – является функция прибыли, которая рассчитывалась для каждого из временных срезов t на горизонте управления состоящего из T временных срезов. Для каждого временного среза t горизонта управления T проводилось восстановление параметров управления – цена $Price_{j,t}$, по соответствующим сгенерированным на j -м интервале дискретности ($j= 1..Nu$) отклонениям цены $U_{j,t}$ и параметров состояния – числа ежедневных продаж $Q_{j,t}$, по полученным от ИНС прогнозным значениям приращений с учетом обратного восстановления. Так же проведено восстановление от проведенных нормировок, необходимых для корректного обучения ИНС, в которое входит умножение на нормировочный множитель $Normir$ (перед обучением ИНС значения разностей делились на $Normir=40$, чтобы с гарантией обеспечить значения приращений параметров, поданных на нейросеть, в диапазоне $[-1,1]$), и суммирование с последними известными значениями Y_{fin} , P_{fin} и рассчитанных прогнозных значений для временных срезов горизонта управления -количеств продаж $Q_{j,t}$ и цен $Price_{j,t}$,

$$Q_{j,t} = y_{fin} + \left(\sum_{u=0}^t Y_{j,t} \right) Normir \quad Price_{j,t} = p_{fin} + \left(\sum_{u=0}^t U_{j,t} \right) Normir$$

$$P_t = Q_t * (Price_t - NetCost). \quad (6)$$

Задача оптимизации заключается в нахождении набора U_t :

$$U_t = Argmax_{U_t} \sum_{t=1}^T < P_t >, \quad (7)$$

где $< P_t >$ – кортежи значений функции прибыли для временных срезов t горизонта управления, рассчитанных по восстановленным прогнозным значениям среднесуточных продаж Q_t , и восстановленным значениям среднесуточной цены $Price_t$ на временных срезах t горизонта управления, $NetCost$ – себестоимость товара.

Оптимизация проводилась в 2 этапа. На первом этапе весь диапазон возможных значений управляющего параметра – (значения разностей среднесуточных продаж) для каждого временного среза горизонта управления $[U_{min_t}, U_{max_t}]$ делился на некоторое число интервалов дискретности Nd (в нашем случае $Nd=100$). Затем из полученных дискретных зна-

чений U_{j_t} для каждого временного среза t с генератором целых чисел генерировался номер n_t интервала дискретности из набора номеров $\{1, 2, \dots, Nd\}$ и выбирался набор значений приращения цены U_{n_t} по одному для каждого временного среза горизонта управления. Для этого набора с помощью (1) и (2) вычислялись соответствующие значения параметров состояния Y_{n_t} (приращение числа продаж в сутки) для которых по (6) вычислялись наборы значений целевой функции- функции прибыли P_{n_t} . Диапазон значений управляющего параметра U (приращение цены), рассчитанного по правилу 3 сигма составил значения от -80.371 до 80.371 . По наборам P_{n_t} , полученных случайным сэмплением при числе попыток $Ns=1000$, вычислялась локально-оптимальная траектория, обладающей максимальной суммой P_{n_t} по всем временным срезам t . В результате случайного сэмпирования из 1000 полученных траекторий была выбрана одна с максимальной суммой, которую обозначаем как $M1$. В итоге для используемой ИНС модели выбрана локально-оптимальная траектория для которой получено значение суммы целевой функции (функции прибыли предприятия) по всем временным срезам горизонта управления: $M1=48518.902$.

На втором этапе алгоритм сэмпирования начинается с деления диапазона возможных значений $[U_{min_t}, U_{max_t}]$ на $Nu=10$ одинаковых интервалов и построения одинаковых бэта-распределений для этих интервалов с параметрами $a=2.01$, $b=3.01$.

Для каждой i -й итерации сэмпирования ($i=1..Ns$) в соответствии с описанным выше модифицированным Томпсоновским алгоритмом для каждого временного среза выбирается интервал с максимальным значением $f_{j,t}$, рассчитанным согласно (4) с учетом параметров бэта-распределений $\alpha_{j,t}$ и $\beta_{j,t}$ из которого выбиралось $U_{n_{i,t}}$, согласно (1), (2) рассчитывалось $Y_{n_{i,t}}$, согласно (6) рассчитывалось P_t , согласно (7) – рассчитывалась сумма прибыли M_i по траектории. Если $M_i > M1 * 0.5$ то согласно (5) корректировались $\alpha_{j,t}$ и $\beta_{j,t}$. При этом параметр корректировки γ в работе [Ferreira K.J., 2015] предлагается выбирать порядка $1/\sqrt{Ns * \log(Ns)}$

После 1000 последовательных итераций сэмпирования получена следующая картина распределения количества сэмплов, приходящихся на определенный интервал (см Рис 2а)

На рис. 2,б) распределение количества сэмплов по интервалам дано для $Nu=10$ и $Ns=5000$ итераций сэмпирования.




Рис. 2,а




Рис. 2,б

Результатом сэмпирования по предложенному модифицированному Томпсоновскому алгоритму с общим числом в 1000 попыток стала траектория, которая приводит к значению суммы целевой функции (прибыль предприятия-продавца) $M_2=88776.489$, т.е. вдвое превышающую сумму прибыли, полученную для оптимальной траектории выбранной случайным сэмпированием за 1000 попыток. На рис. 3 показано смещение медианы распределений для наиболее «успешных» интервалов при «мягком» изменении параметров распределений за счет вознаграждения (рис 3,а) $r=1/N_s$ и более жестком изменении параметров распределений рис. 3,б) $r=50/N_s$. При этом, при большем количестве сэмпирований $N_s=5000$, но более жестком методе применения вознаграждения разница в эффективности случайного сэмпирования и модифицированного алгоритма Томпсоновского сэмпирования сократилась: $M_1=54489.066$, $M_2=69028.902$. Применение промежуточных параметров увеличило эффективность по сравнению с жестким подходом, но оказалось все равно менее эффективно «мягкого подхода» $M_1=48552.101$, $M_2=70581.827$ при $N_s=2500$, $N_u=10$, $r=10/N_s$. Распределение числа сэмплов по интервалам и эволюция функций плотности бета-распределений приведены на рис. 4,а и 4,б)




Рис. 3,а




Рис. 3,б




Рис. 4,а




Рис. 4,б

Для этого варианта локально-оптимальная траектория приращений управляющего параметра (цены) выглядит следующим образом [80.3 74.7 76.2 79.3 72.8 70.7 78.8 -46.8 77.]. На временных срезах 1-7 система предлагает выбирать приращения цены , близкие к максимально-возможным. На 8-м срезе – снизить цену и снова поднять на 9м временном срезе.

Заключение

Рассмотренные в работе разработанные автором способы и алгоритмы построения прогнозирующей модели объекта управления на основе искусственной нейронной сети, а так же модифицированный алгоритм Томпсоновского сэмплирования для определения оптимального набора управляющих параметров, доставляющих максимальную сумму целевой функции по всем срезам горизонта управления, хорошо зарекомендовали себя на конкретном примере предсказания оптимальных цен реализации товара на маркетплейсе. Расчет оптимальных цен произведен для 9 временных срезов на горизонте управления более месяца при использовании временных рядов данных по среднесуточной цене на товар и по среднесуточным количествам продаж данного товара на маркетплейсе, записанных в течении 497 суток.

Список литературы

- [Томпсон, У.Р., 1935]Томпсон У.Р. О теории распределения // Американский журнал математики. – (1935). – 57 (2). – С. 450-456.
- [Даниэль Дж. Руссо, 2018]Даниэль Дж. Руссо, Бенджамин Ван Рой, Аббас Казе-руни, Ян Осбанд и Чжэн Вэнь. Учебное пособие по выборке Томпсона // Основы и тенденции в машинном обучении. – 2018. – Т. 11, № 1. – С. 1-96. – https://web.stanford.edu/~bvr/пабы/TS_Tutorial.pdf.

- [Ferreira K.J., 2015] Ferreira K.J., David Simchi-levi, He Wang. Online Network Revenue Management Using Thompson Sampling. January 2015 SSRN Electronic Journal. DOI:10.2139/ssrn.2588730.
- [Чернышев Л.С., 2021]. Чернышев Л.С. Способ и система для прогнозирования значений временного ряда с использованием искусственной нейронной сети. Патент на изобретение 2744041 С1, 02.03.2021. Заявка № 2019128366 от 10.09.2019.
- [Чернышев Л.С., 2022a]. Чернышев Л.С. (ООО «Матсофт»). Заявка на изобретение. Рег. номер ФИПС 2022123701 от 06.09.2022. «Способ и система управления технической системой или процессом с помощью искусственной нейронной сети, оптимизирующий целевую функцию».
- [Чернышев Л.С., 2022б]. Чернышев Л.С. Способ управления технической системой или процессом с помощью искусственной нейронной сети, оптимизирующий целевую функцию». Текст доклада конференции.
- [Хайкин С., 2006] Хайкин С. Нейронные сети: полный курс. – 2-е изд.: пер. с англ. – М.: Издательский дом «Вильямс», 2006. – 1104 с.
- Галушкин А.И., 2000] Галушкин А.И. Теория нейронных сетей. Кн. 1. – М.: ИПРЖР, 2000. – 416 с. (Нейрокомпьютеры и их применение).
- [Егупов Н.Д., 2002]. Методы робастного, нейро-нечёткого и адаптивного управления: учебник / под ред. Н.Д. Егупова. – 2-е изд. стер. – М.: Изд-во МГТУ им Н.Э. Баумана, 2002. – 744 с. ил. – ISBN 5-7038-2030-8, тир. 2000 экз, Ч. 2 «Нечёткое управление».
- [Макаров И.М., 2006] Макаров И.М., Лохин В.М., Манько С.В., Романов М.П. Искусственный интеллект и интеллектуальные системы управления. – М.: Наука, 2006.
- [Пупков К.А., 1994]. Пупков К.А. Проблемы теории и практики интеллектуальных систем // Машиностроение, приборостроение, энергетика / ред. кол.: Тихонов А.Н., Садовничий В.А и др. – М.: Изд-во Моск. ун-та, 1994. – С.263-266.
- [Тимофеев А.В., 1994] Тимофеев А.В., Юсупов Р.М. Интеллектуальные системы управления // Известия РАН. Тех. Кибернетика. – 1994. – № 5. – С.209-224. 50.
- [Терехов В.А., 1999] Терехов В.А., Ефимов Д.В., Тюкин И.Ю., Антонов В.Н. Нейросетевые системы управления. – СПб: Изд-во С.-Петербургского университета, 1999.

Abstracts of Sectional Reports

Section 3

Neural Network, Fuzzy Methods. Soft Measurements and Calculations

INPUT RATE-DEPENDENT MEMORY CAPACITY OF THE RESERVOIR COMPUTER

E.A. Viktorov (*evviktor@gmail.com*)

G.O. Danilenko (*danilenko.gleb98@gmail.com*)

A.V. Kovalev (*avkovalev@itmo.ru*)

ITMO University, Saint-Petersburg, Russia

The paper presents the results of a study of the effect of data input time on the memory capacity of a reservoir computing system based on a semiconductor laser with optoelectronic feedback with filtration. The effect of memory capacity reduction is demonstrated when the data input period coincides with the periods of the system's eigen oscillations. The change of the memory capacity resonant dips with

HYBRID ALGORITHM FOR SOLVING THE PROBLEM OF PLACEMENT OF ELEMENTS OF COMPUTING EQUIPMENT

L.A. Gladkov (*leo_gladkov@mail.ru*)

M.D. Yasir (*yasir_82@mail.ru*)

N.V. Gladkova (*nadyusha.gladkova77@mail.ru*)

Southern Federal University, Taganrog, Russia

In the article, the problem of placing elements of different sizes is discussed. The statement of the problem, as well as the main limitations and optimization criterion is given. A model of a hybrid algorithm for solving the placement problem is developed. A model of a parallel multipopulation genetic algorithm is proposed. A procedure that allows implementing the principle of multithreading at the local level, when calculating the values of objective functions, has been developed. The principles of operation and the structure of the fuzzy control block are described. A model of a multilayer neural network that implements the function of a neuro-fuzzy control block is proposed. The control parameters of the genetic algorithm are chosen. The proposed hybrid algorithm is implemented as an application program. A series of computational experiments to determine the efficiency of the developed algorithm and to select the optimal values of the control parameters was carried out.

EVIDENCE THEORY APPLICATION FOR ANFIS/TSK FUZZY NEURAL NETWORKS TRAINING IN DIAGNOSTIC SYSTEMS

V.K. Ivanov (*mtivk@mail.ru*)

B.V. Palyukh (*pboris@tstu.tver.ru*)

Tver State Technical University, Tver, Russia

The paper substantiates a method for creating training data sets for a fuzzy neural network, which can be used to quickly obtain probabilistic estimates of incidents causes in diagnostic systems. The rules for converting hypotheses about potential causes of incidents into intervals of defect probability in the technological chain at some continuous production stage using belief functions are considered. A procedure is proposed for automatically converting these hypotheses into a fuzzy production rules base, which provides training for the ANFIS neural network with the Takagi-Sugeno-Kang fuzzy logic system. This will allow you to quickly determine an estimate of the malfunction probability in the process chain that is sufficiently correct for practical use without using expensive computing resources.

WORLD MODEL FOR ACTOR AND CRITIC IN REINFORCEMENT LEARNING

A.I. Panov (*pan@isa.ru*)

Federal Research Center "Informatics and Management" of the RAS,
Moscow; Russia

AI Institute of Artificial Intelligence, Moscow, Russia

L.A. Ugadyarov (*ulaelfray@gmail.com*)

Moscow Institute of Physics and Technology (National Research University),
Moscow, Russia

Model-based reinforcement learning is a hybrid approach that combines planning and model-free learning has a strong advantage of being sample efficient. Model-based methods simulate trajectories by interacting with the model in order to directly train the policy or to approximate the state value function and use it to estimate state-action values along the multi-step simulated trajectories. In this paper we propose a novel approach to integrate an environment model and actor-critic methods that employs the model as a critic to estimate the state-action value function. Experiments with hybrid actor-critic algorithms using a look-ahead tree-structured model as a critic in environments with a complex set of subgoals have shown that the proposed integration can speed up the learning process under certain conditions.

INFERENCE METHOD FOR MAMDANI-TYPE SYSTEMS WITH NON-SINGLETON FUZZIFICATION

V.G. Sinuk (*vgsinuk@mail.ru*)
S.A. Karatach (*karatach1998@yandex.ru*)
BSTU after V.G. Shukhov, Belgorod, Russia

The article presents the result of logical inference for widely used fuzzy Mamdani-type systems with non-singleton fuzzification. It was achieved on the basis of an approach using a fuzzy truth value, which made it possible to reduce the problem to polynomial computational complexity and generalize the conditions for logical inference. Using the method of defuzzification of the center of sums, the ratios of the output of a fuzzy system for certain functions of the accessories of the consequent rules are obtained.

APPLICATION OF OPTIMUM ADAPTIVE GENERALIZED PREDICTIVE CONTROL TO GREEN TEA DRYING

K.B. Fam
P.M. Murashev
V.N. Bogatikov (*phambang79520897405@gmail.com*)
Tver State Technical University, Tver', Russia

One of the most frequently used operations in the processing industry is food drying. This is a complex, multi-parameter, non-linear dynamic system, the degree of non-linearity of which is determined by the operating range of the drying process. For a dryer to operate efficiently, it must not only be well designed, but the control strategies implemented must also be effective. And the drying process control system must maintain the necessary controlled variables in the face of many disturbances that arise in production situations and the uncertainty of the conditions of the drying process. In the article, to improve the quality of process control under uncertainty in the conditions of the drying process, design methods are applied based on the use of a predictive controller for the state of system parameters using the Box-Wilson optimization method and the “experiment planning” technique. In general, the results of the simulation of the green tea drying process control system show that the Model predictive control (MPC) controller is stable and stable in terms of suppressing input disturbances. The control system of the MPC, when implementing the Box-Wilson method for the object model, provides relatively more efficient operation compared to traditional MPC.

ARTIFICIAL NEURAL NETWORKS BASED ON NON-BINARY NEURONS WITH TIME SUMMATION OF SIGNALS IN INTELLIGENT SYSTEMS

A.A. Kharlamov (*kharlamov@analyst.ru*)
Institute of Higher Nervous Activity and Neurophysiology of RAS, Moscow,
Moscow State Linguistic University, Moscow,
Higher School of Economics, Moscow,
Moscow Institute of Physics and Technology, Dolgoprudny, Russia

N.S. Borodin (*nsborodin@edu.hse.ru*)
Higher School of Economics, Moscow, Russia

The paper describes artificial neural networks based on neurons with temporal summation of signals, including structural processing of input sequences. The class of networks is shown to be extended to the non-binary case of the analyzed input sequences. The performance of such networks trained on the code sequences of spoken speech is shown in a specific context of speech wave synthesis.

DYNAMIC MODEL OF OPTIMAL CONTROL OF ARTIFICIAL NEURAL NETWORK LEARNING

E.G. Tsarkova (*univesrity69@mail.ru*)
Tver State Technical University, Tver, Russia

In this paper, modeling of an artificial neural network is carried out, an algorithm for training a neural network model described by a system of differential equations is developed. To solve the problem of INS training, an optimal control apparatus is used. Taking into account the given constraints and the type of the target functional, the necessary optimality conditions for the weighting coefficients of the network and external control action are formulated, the corresponding discrete optimal control problem is constructed, for the solution of which the method of rapid automatic differentiation can be applied.

FUZZY MODELS AS A FORMALIZATION OF EXPERTS' EVALUATION KNOWLEDGE

G.E. Yakhyaeva (*gul_nara@mail.ru*)
O.D. Palchunova (*o.palchunova@g.nsu.ru*)
Novosibirsk State University, Novosibirsk, Russia

Evaluative knowledge about the object domain can be represented not only in the form of objective (statistical) probability, but also in the form of subjective (expert) probability. Expert evaluations may be incomplete, inconsistent with each other. An expert consistency check tool is needed. The paper proposes a formalization of subjective interpretations of probability in the language of the theory of fuzzy models. This allows us to formulate criteria for the consistency of the evaluate knowledge received from experts. The article describes various properties of consistent evaluative knowledge, considers the concept of a minimal fuzzy model consistent with a given evaluative knowledge, and investigates the uniqueness criteria for such a model.

Section 4

Applied Intelligent Systems. Tools for Building Intelligent Systems

INTELLIGENT INFORMATION TECHNOLOGIES IN THE ARMED FORCES UNITS

G.P. Vinogradov (*wgp272ng@mail.ru*)
Research Institute of Centerprogram Systems, Tver,
Tver State Technical University, Tver, Russia

The intellectualization of automated systems and complexes in the Armed Forces of the Russian Federation involves the use of knowledge-based methods and technologies. This requires the construction of a knowledge engineering cycle, including the stages of perception, representation, awareness, and replenishment of knowledge. The paper considers one of the key stages – the stage of acquiring knowledge from distributed sources. The proposed solution is based on the use of SCADA tools and sensor networks through their integration, as well as hybridization with expert knowledge.

SEMANTIC TECHNOLOGIES FOR THE DEVELOPMENT OF IMMERSIVE VIRTUAL ENVIRONMENTS WITH BIOFEEDBACK

V.V. Gribova (*gribova@dvo.ru*)
V.O. Strekalev (*strekalev.vo@dvo.ru*)
Institute of Automation and Control Processes FEB RAS,
Vladivostok, Russia

The paper describes the development and maintenance of virtual simulators with bio-feedback using semantic technologies and ontological representation of information. The proposed solution is based on the principle of a clear separation between declarative knowledge (domain knowledge) and procedural (about the method of solving the problem). The principles of formation of each component – knowledge and data base, problem solver and user interface are described.

EXTENSION OF AN INTELLIGENT SYSTEM FOR SUPPORTING SCIENTIFIC RESEARCH IN FORENSIC SCIENCE

S.M. Gusakova (*svem45@yandex.ru*)
Federal Research Center «Computer Science and Control», RAS,
Moscow, Russia

N.V. Ogoreltseva (*nat@gmail.com*)
Tinkoff Bank, Moscow, Russia

The report describes the extension of the functionality of the intelligent DSM system for psychological and forensic research. The results of the conducted experiments are presented.

CREATING PROTOTYPES OF CASE BASES WITH THE AID OF DECISION TABLE TRANSFORMATIONS TO PREDICT THE RISK OF FOREST FIRES

N.O. Dorodnykh (*tualatin32@mail.ru*)

O.A. Nikolayghuk (*nikoly@icc.ru*)

A.Yu. Yurin (*iskander@icc.ru*)

Institute for System Dynamics and Control Theory of Siberian
Branch of Russian Academy of Sciences, Irkutsk, Russia

Improving the efficiency of the creation of knowledge bases for intelligent decision support systems continues to be an urgent scientific and technical task. The paper describes the application of an original approach using the principles of model-driven development and transformations to create prototypes of case bases. The approach provides the transformation of decision tables to obtain cases of the simplest parametric form. The description of the main stages of the approach and an example of its application in prototyping the knowledge base of the forest fire forecasting service are presented.

APPLICATION OF INTELLIGENT METHODS OF SYSTEM EVENT CORRELATION IN PREDICTIVE ANALYTICS OF SECURITY STATES OF CRITICALLY IMPORTANT INFRASTRUCTURE OBJECTS

I.V. Kotenko (*ivkote@comsec.spb.ru*)

D.A. Levshun (*gaifulina@comsec.spb.ru*)

St. Petersburg Federal Research Center of the Russian Academy of Sciences,
St. Petersburg, Russia

The paper proposes a technique for applying intelligent methods for system event correlation, which performs predictive analytics of security states. The proposed technique allows identifying similar system events, detecting cause relationships between them, and identifying the corresponding security states at the early stages of the event scenario development in case of failures and implementation of deliberate threats (attacks). We use the clustering method to analyze the similarity of events, and the autoencoder with a bidirectional recurrent network to determine and predict sequences of events.

WEAKLY STRUCTURED SOCIO-ECONOMIC SYSTEMS RESEARCH BASED ON A HYBRID COGNITIVE MAP IN COMBINATION WITH A SELECTIVE DENDRITIC NEURAL NETWORK

M.E. Mazurov (*mazurov37@mail.ru*)

A.A. Mikryukov (*mikrukov.aa@rea.ru*)

Plekhanov Russian University of Economics, Moscow, Russia

The results of mathematical modeling of cognitive maps in combination with selective dendritic networks of neurons, which, with a certain organization, have computational and cognitive properties, are presented. The possibility of increasing the efficiency of using a model for predicting the development of a university based on a cognitive map in combination with a selective dendritic network of neurons is shown. The proposed structure of

hybrid cognitive maps allows a natural simplification of the structure by removing non-working network connections of the global structure, provides a universal matrix description of the network mathematical model, as well as the effective formation of a computational algorithm and software for solving problems of predicting university development indicators. During the research, a hybrid cognitive model was developed for scenario forecasting of measures to achieve the required values of the university's target indicators in the QS international institutional ranking. The possibility of forming a cognitive map based on a multilayer dendritic network of direct propagation in the presence of unidirectional links of its concepts is shown. The results obtained made it possible to form a scenario plan for the necessary stepwise increase in the values of target indicators, considering the latent factors influencing them in the interval of 2020–2025.

DEVELOPMENT OF A SYSTEM FOR DETECTING UNUSABLE MARBLE WITH CONVOLUTIONAL NEURAL NETWORKS

A.S. Mokhov (*mokhovas@mpei.ru*)

D.A. Shestov (*shestovda@mpei.ru*)

I.V. Shubin (*ShubinIV@mpei.ru*)

National Research University "Moscow Power Engineering Institute",
Moscow, Russia

This work is devoted to the selection and configuration of a convolutional neural network for recognizing marble on a conveyor belt that is unsuitable for processing, as well as creating an application that returns coordinates of unsuitable marble for removal from the belt.

AUTOMATION OF PROGRAM CODE ANALYSIS USING MACHINE LEARNING METHODS

V.S. Moshkin (*postforvadim@ya.ru*)

A.A. Dyrnochkin (*dyrno4kin@gmail.com*)

N.G. Yarushkina (*jng@ulstu.ru*)

Ulyanovsk state technical university, Ulyanovsk, Russia

The paper presents a description of the developed approach and service for analyzing source code in Python. The service reduces the time for code review due to partial automation. The FastText algorithm is used to obtain vector representations of source code texts. A pre-trained neural network language model based on the transformer architecture was used to derive a possible natural language function assignment. A classifier based on the gradient boosting algorithm was used to detect duplicate PR. The developed service checks the changeset and publishes error and duplicate reports in changeset comment format after the changeset is published to a remote Git repository. The conducted testing did not reveal any errors that affect the operation. All the main functions of the system are performed correctly.

TECHNOLOGIES OF KNOWLEDGE ENGINEERING IN EATING BEHAVIOR DIAGNOSIS

D.Z. Nagaeva (*nolandi@yandex.ru*)
E.Yu. Sazonova (*ekaterina_rassadnikova@mail.ru*)
O.N. Smetanina (*smoljushka@mail.ru*)
V.S. Sazonov (*sazonov_vladimir93@mail.ru*)
Ufa University of Science and Technology, Ufa, Russia

This article deals with the use of knowledge engineering technologies in a comprehensive assessment of eating behavior. The authors provide an analysis of the current state in the field of assessment of eating behavior, the formulation of the problem of a comprehensive assessment of eating behavior and an approach to its solution. A comprehensive assessment is aimed at forming a sample of recommendations based on the class (personality type). Classification is carried out on the basis of data collected as a result of a person passing the MMPI psychological test (566 questions, 32 rating scales). Formalization of knowledge using production models is carried out taking into account the knowledge of experts about products containing certain types of hormones and providing an improvement in mood compared to the results of passing a mood test, which includes five basic emotions; about improving the quality of eating behavior based on the results of a behavioral text that includes 10 additional questions; about foods containing essential vitamins, minerals, and amino acids based on a nutrient detection test. The results obtained formed the basis of the developed BestBody mobile application for Android operating system.

MODERN ARCHITECTURES OF INTELLIGENT TUTORING SYSTEMS BASED ON INTEGRATED EXPERT SYSTEMS: FEATURES OF THE APPROACH TO THE AUTOMATED FORMATION OF THE ONTOLOGICAL SPACE OF STUDENTS KNOWLEDGE AND SKILLS

G.V. Rybina (*gvrybina@yandex.ru*)
A.A. Grigor'ev (*grigandal625@gmail.com*)
National Research Nuclear University "MEPhI", Moscow, Russia

The features of the main types of architectures of modern intelligent tutoring systems (ITS) and their development paradigms are analyzed. Particular attention is paid to ITS based on the architecture of tutoring integrated expert systems (IES) and tutoring web-IES, the basic principles and development technology of which are generally determined by the problem-oriented methodology for building IES and the AT-TECHNOLOGY workbench tools. The prerequisites, the results obtained and further prospects for the automated formation of a unified ontological space of knowledge and skills of students are discussed through the use of tutoring web-IES throughout the entire learning cycle.

STUDY OF THE POSSIBILITIES OF DETECTING ABNORMAL BEHAVIOR OF USERS OF DATA CENTERS BASED ON MACHINE LEARNING MODELS

I.B. Saenko (*ibsaen@comsec.spb.ru*)

I.V. Kotenko (*ivkote@comsec.spb.ru*)

St. Petersburg Federal Research Center of the RAS, St. Petersburg, Russia

Mazen H. Al-Barri (*mazenb51@gmail.com*)

Military Communications Academy, St. Petersburg, Russia

The paper describes the main points of the proposed method for detecting abnormal behavior of data center users, which uses machine learning models. Issues related to the formation of the feature space for machine learning models, software implementation and experimental evaluation of the proposed method are considered.

NEURAL NETWORK APPROACH TO STRUCTURAL-SEMANTIC ANALYSIS OF DIGITAL DOCUMENTS

N.S. Skrynnikova (*skrynnikovns@mpei.ru*)

O.L. Morosin (*morosinol@mpei.ru*)

National Research University "Moscow Power Engineering Institute",
Moscow, Russia

This paper describes a way of applying the neural network approach to the task of structural-semantic analysis of documents. The distinctive feature of the developed algorithm is the joint use of both textual and graphical elements of the document, which improves the quality of recognition even with noisy input data.

Section 5

Intelligent Decision Support and Management Systems

CREATING DIGITAL PATIENT-ORIENTED RECOMMENDATIONS BASED ON MULTILEVEL GRANULATION

T.V. Afanas'eva (*afanaseva.tv@rea.ru*)

Plekhanov Russian University of Economics, Moscow, Russia

P.V. Platov (*chipa.platov@gmail.com*)

Ulyanovsk State Technical University, Ulyanovsk, Russia

The development of digital technologies in the field of healthcare, disease prevention and patient awareness of existing diseases has led to the emergence of new patient support systems, called health recommendation systems. Based on the analysis of such systems, the article introduces the definition of patient-oriented systems, proposes models of patient health and digital patient-oriented recommendations, as well as a scenario for their creation using multi-level information granulation in the spatial-temporal aspect.

THE METHOD OF INTELLIGENT LOGISTIC DECISION SUPPORT BASED ON GENETIC CLUSTERING AND FUZZY MODELING

V.V. Borisov (*vbor67@mail.ru*)

A.V. Ryazanov (*ballack.1391@mail.ru*)

The Branch of National Research University

“Moscow Power Engineering Institute» in Smolensk, Russia

A.V. Bobryakov (*avbob@mail.ru*)

National Research University “Moscow Power Engineering Institute»,
Moscow, Russia

This paper proposes the method of intelligent logistic decision support based on genetic clustering and fuzzy modeling. The formulation of the research task is carried out and the solution of the following interrelated tasks is presented: firstly, the division of the logistics service territory into zones; secondly, the determination of the required number of vehicles when distributing logistics orders by zones; thirdly, the assignment of vehicles to fulfill logistics orders. The use of the proposed method (using the example of online orders of vehicles) makes it possible to improve the quality and efficiency of logistics decisions.

BASIC TRENDS IN DECENTRALIZED ARTIFICIAL INTELLIGENCE

V.I. Gorodetskiy (*vladim.gorodetskiy@gmail.com*)

JSC "EVRIKA", St. Petersburg, Russia

The analysis of current trends, advanced concepts and projects under development in the field of information technology shows the increasing role of AI, and primarily decentralized AI. This paper analyzes the advanced concepts of building next-generation IT applications and applied developments, gives a brief analysis of current advances in decentralized AI and self-organization, which are able to support the practical implementation of modern applications, and formulates a simplified analogue of the roadmap for the perspective research and developments in the area of decentralized and self-organizing AI for the near future.

AN INTELLIGENT SYSTEM FOR PRESCRIBING PERSONALIZED TREATMENT BY CASE BASED REASONING

V.V. Gribova (*gribova@iacp.dvo.ru*)

R.I. Kovalev (*koval-995@mail.ru*)

Institute of Automation and Control Processes Far Eastern

Branch of the Russian Academy of Sciences,

Far Eastern Federal University, Vladivostok, Russia

D.B. Okun (*okdm@iacp.dvo.ru*)

Institute of Automation and Control Processes Far Eastern

Branch of the Russian Academy of Sciences, Vladivostok, Russia

The paper describes a system of prescribing treatment based on precedents. The requirements and principles of the system have been formed. A unique feature is the extraction of use cases based on a hybrid approach.

CORRECTION OF ERRORS DURING LEARNING IN THE INTELLIGENT ROBOT CONTROL TASK

D.A. Dobrynin (*rabota51@mail.ru*)

Federal Research Center for Computer Science and Control RAS,

Moscow, Russia

The paper describes an approach to improving the quality of training of an intelligent robot control system based on error correction. The training of a mobile robot to move along a contrast strip was chosen as a model task. It is shown that the quality of training can be improved by removing bad hypotheses and subsequent retraining. Experiments on a robot simulator have shown an improvement in learning outcomes when using error correction.

**INTEGRATION OF THE METHODS OF SYSTEM ANALYSIS
AND COGNITIVE GRAPHICS IN THE EARLY DIAGNOSIS
OF VISION PATHOLOGY**

A.P. Ereemeev (*eremeev@appmat.ru*)

O.S. Kolosov (*KolosovOS@mpei.ru*)

National Research University "Moscow Power Engineering Institute",
Moscow, Russia

M.V. Zueva (*visionlab@yandex.ru*)

I.V. Tsapenko (*sunvision@mail.ru*)

Helmholtz National Medical Research Center for Eye Diseases, Moscow, Russia

The paper represents the possibilities of computerization of early diagnosis of complex pathologies of vision are considered on the example of diseases of the retina. Data from a special medical device, an electroretinography, are used as the initial data for intellectual analysis, which are processed using methods of analysis of complex systems (Fourier expansion, spectral analysis, analysis of changes in the amplitude- and phase-frequency characteristics of the retina in different testing modes), methods of artificial intelligence (fuzzy logic, production rules formed on the basis of the knowledge of expert physiologists) and methods of cognitive graphics for the figurative representation of retinal states. Research and development are carried out by specialists from National Research University "Moscow Power Engineering Institute" and Helmholtz National Medical Research Center of Eye Diseases in terms of developing an intelligent decision support system for the early diagnosis of retinal pathologies.

VIBRATORY MACHINE CONTROL BASED ON HEURISTIC ALGORITHM

Yu.S. Zaytseva (*julia.zaytsev@gmail.com*)

B.R. Andrievskiy (*boris.andrievsky@gmail.com*)

Institute for Problems in Mechanical Engineering RAS,
St. Petersburg State University, St. Petersburg, Russia

The use of intelligent methods in the field of mechatronics and robotics is a hot topic due to the need for the industry to switch to digital technologies. This paper presents an approach to machine learning of the control loop of an electromechanical system with an actuating drive mechanism. The real-time control system maintains the specified drive rotation speed using a discrete PI controller implemented in the MATLAB/Simulink environment. The learning task for the system is to maximize the speed of the drive directly on the running plant, while the controller parameters are adjusted automatically. Training is carried out using the simplex method and a random search algorithm. The results of the experiments are presented as illustrations of the operation of both algorithms.

INDUSTRY 5.0: BASIS FOR CREATING NEURO-DIGITAL INTELLIGENCE ON THE EXAMPLE OF SPACEX COMPANY

A.V. Kolesnikov (*avkolesnikov@yandex.ru*)

S.I. Koryagin (*skoryagin@kantiana.ru*)

I.V. Lieberman (*iliberman@kantiana.ru*)

P.M. Klachek (*pklachek@mail.ru*)

Immanuel Kant Baltic Federal University, Kaliningrad, Russia

A.V. Babkin (*al-vas@mail.ru*)

St. Petersburg Polytechnic University of Peter the Great, St. Petersburg, Russia

The main features of the integrated model of the global transformation of society based on the movement towards the no-society and the neurosphere, which can become the basis for creating cyber-social ecosystems of Industry 5.0, are considered. A model of neuro-digital intelligence of tools for strategic goal-setting and planning of Industry 5.0 is proposed, which represents a special kind of convergence of the cyber world of collective intelligence with the physical world of industrial operational technologies of Industry 5.0. An applied model of the SpaceX transformation ecosystem and the SpaceX cognitive production model developed on its basis based on neuro-digital intelligence, as well as the results of their implementation within the SpaceX Starship project, are presented.

INTELLIGENT DECISION SUPPORT SYSTEM FOR FLEET MAINTENANCE

A.V. Kolesnikov (*a.kolesnikov@yandex.ru*)

Baltic Federal University named after I. Kant, Kaliningrad, Russia

E.I. Mukhitov (*mukh70@yandex.ru*)

Management of the Baltic Fleet, Kaliningrad, Russia

The relevance of decision-making support for the technical support of the fleet forces is substantiated. The conceptual model of the hierarchy of the fleet technical support management system is considered, as well as the transformation of unstructured information into structured data. A conceptual model of a logistics information and intelligent system to support decision-making on fleet maintenance and requirements for its hardware and software appearance, the results of ontological modeling and decomposition of management problems are presented.

SEMIOTIC MODEL OF MENTAL SPACE

A.A. Kulinich (*alexkul@rambler.ru*)

V.A. Trapeznikov Institute of Control Sciences, RAS, Moscow, Russia

As a decision support model, it is proposed to consider a qualitative model of the human mental space. In contrast to Kahneman's two-process model, the mental space model represents the image of the problem being solved (representation), in terms of human experience and various mechanisms for manipulating the elements of the image with the

involvement of personal knowledge, knowledge acquired on the Internet, which allows you to rebuild the initial representation before representing the solution. In this case, decision support is aimed not at combating cognitive distortions, but at supporting the structural characteristics of the mental space, which provide high intellectual productivity of the decision maker.

COGNITIVE MODELING OF UNIVERSITY ACTIVITY AS A WEAKLY STRUCTURED SYSTEM

A.A. Mikryukov (*mikryukov.aa@rea.ru*)

M.E. Mazurov (*mazurov37@mail.ru*)

Russian Economic University, Moscow, Russia

The relevance of the problem being solved is due to the need to develop evidence-based proposals to achieve the required values of the basic indicators of the university's activities in accordance with the international institutional rating QS to the required values necessary for the university to enter the TOP-500 universities by 2025. To solve this problem, an approach to the study of weakly structured systems, the class of which includes universities and their activities, is proposed based on scenario forecasting methods by building a fuzzy cognitive model to determine the necessary increments in the values of target indicators. The proposed approach allows, under the given constraints, to find the most appropriate scenario for planning the increment of base indicators to target values by identifying the latent factors influencing them and impulsive effects (increments) on them, ensuring the guaranteed achievement of the set goal. The results obtained make it possible to substantiate annual costs in the future to ensure an unconditional increment in the values of latent factors (private indicators) to guarantee the required values of basic indicators by 2025. The novelty of the proposed approach lies in the use in constructing a fuzzy cognitive model of correlation relationships of latent factors identified based on factor analysis methods with basic indicators, as well as in applying an iterative approach to solving the problem, which allows to update a set of initial data, as well as to train the developed cognitive model, considering the results of identifying latent factors and adjusting their correlations. The results obtained make it possible to form the most preferable scenario plan for the necessary stepwise increase in the values of basic indicators in the interval of 2020–2025. subject to resource constraints.

HYBRID INTELLIGENT SYSTEMS FOR PERSONALIZED HEALTH ASSESSMENT OF THE STATE OF COMPLEX OBJECTS USING DYNAMIC MODELING OF THE EXAMINEE

S.B. Rumovskaya (*sophiyabr@gmail.com*)

Federal Research Center "Computer Science and Management"
of the RAS, Kaliningrad, Russia

The paper considers the features of the problem of assessing the functions of diagnosed complex objects in medicine and their defects risk in order to establish a complete differential diagnosis and predict their condition. It also proposes to develop and investigate

methods and models of a new class of hybrid artificial intelligence systems for medical diagnosis and prognosis. Such systems will integrate heterogeneous knowledge about the process of diagnosing, predicting outcomes and interpreting the prognosis of identified dysfunctions and pathologies in complex objects by combining models of hybrid intelligent systems of two types (functional and transformational) as well as including a model of the functioning of a complex object as a heterogeneous biological system.

AN APPROACH TO THE IMPLEMENTATION OF CROSS-CUTTING VISUAL SUPPORT OF DECISION-MAKING PROCESSES FOR INTELLECTUAL TUTORING SYSTEMS

V.A. Uglev (*vauglev@sfu-kras.ru*)

Siberian Federal University, Krasnoyarsk, Russia

T.A. Gavrilova (*gavrilova@gsom.spbu.ru*)

Graduate School of Management, St. Petersburg State University, St. Petersburg

The article describes an approach to supporting the processes of methodological decision-making and their explanation in Intellectual Tutoring Systems (ITS), based on the means of cognitive computer graphics. The importance of Explicable Artificial Intelligence (XAI) issues in the framework of automatic analysis of hypotheses concerning the interpretation of the educational situation is noted. Structural and functional approaches are combined in a single logic; various visual notations are considered. For the proposed decision-making model, vertical (for different scales of coverage of the educational situation) and horizontal (for various aspects of analysis) transitions between decision-making levels are shown. The basis is a combination of the method of Cognitive Maps of Knowledge Diagnosis (CMKD, structural aspect) and the method of Unified Graphic Visualization of Activity (UGVA, functional aspect). The stages of applying data from the student's digital footprint to invariant graphical notations are given. The emphasis is placed on the importance of ensuring the isomorphism of the display of the parameters of the educational situation when switching between images and maps. To illustrate examples from the real educational process, visualizations of CMKD and anthropomorphic UGVA images are given. The advantage of cross-cutting visual support of the decision-making process itself, supplemented by an explanatory text, is demonstrated. At the end of the article, the limitations of the approach are noted and the directions of our further research are given.

THE METHOD OF OPTIMAL CONTROL OF A TECHNICAL SYSTEM OR PROCESS USING A NEURAL NETWORK MODEL AND THOMPSON SAMPLING ALGORITHM

L.S. Chernyshev (*math4soft@yandex.ru*)

Matsoft LLC, Moscow, Russia

The paper proposes an approach to solving the problem of optimal control of a technical system or process (control object) in the form of determining a set of values of control parameters on a set time horizon (control horizon), optimizing the target function of the

control object on this horizon. To solve this problem, a method has been developed for identifying the model of the control object using an artificial neural network (INS). For each given time slice of the required control horizon, the predictive values of the object state parameter are calculated by the INS model based on the values of the object control parameter generated for each time slice of tuples. For each time slice, tuples of the object's objective function are calculated from the generated tuples of control parameters and the tuples of the object's state parameters calculated by the ANN forecast based on them. The solution to the optimal control problem is to select one control parameter value from the generated tuples for each time slice during optimization. The values of the control parameter selected for each time slice jointly provide the optimum of the sum of the values of the objective function for all specified time slices of the required control horizon. Optimization of the objective function of the object is carried out using the Thompson sampling algorithm used in the well-known "Multi-Armed Bandit" problem. As an example, the problem of constructing a set of optimal prices for a product, the sale of which is carried out on the free market, maximizing the profit of the seller for a given management horizon, is solved.

АВТОРСКИЙ УКАЗАТЕЛЬ

Аль-Барри М.Х.	232	Колосов О.С.	313
Андривеский Б.Р.	330	Корягин С.И.	341
Афанасьева Т.В.	251	Котенко И.В.	152, 232
Бабкин А.В.	341	Кулинич А.А.	362
Бобряков А.В.	265	Левшун Д.А.	152
Богатиков В.Н.	65	Либерман И.В.	341
Борисов В.В.	265	Мазуров М.Е.	168, 381
Бородин Н.С.	80	Микрюков А.А.	168, 381
Викторов Е.А.	8	Моросин О.Л.	242
Виноградов Г.П.	110	Мохов А.С.	185
Гаврилова Т.А.	413	Мошкин В.С.	192
Гладков Л.А.	17	Мурашев П.М.	65
Гладкова Н.В.	17	Мухитов Э.И.	351
Городецкий В.И.	275	Нагаева Д.З.	205
Грибова В.В.	122, 292	Николайчук О.А.	141
Григорьев А.А.	218	Огорельцева Н.В.	130
Гусакова С.М.	130	Окунь Д.Б.	292
Даниленко Г.О.	8	Пальчунова О.Д.	97
Добрынин Д.А.	302	Палюх Б.В.	27
Дородных Н.О.	141	Панов А.И.	39
Дырночкин А.А.	192	Платов П.В.	251
Еремеев А.П.	313	Румовская С.Б.	398
Зайцева Ю.С.	330	Рыбина Г.В.	218
Зуева М.В.	313	Рязанов А.В.	265
Иванов В.К.	27	Сасенко И.Б.	232
Каратач С.А.	55	Сазонов В.С.	205
Клачек П.М.	341	Сазонова Е.Ю.	205
Ковалев А.В.	8	Синюк В.Г.	55
Ковалев Р.И.	292	Скрынников Н.С.	242
Колесников А.В.	341, 351	Сметанина О.Н.	205
Стрекалёв В.О.	122	Чернышев Л.С.	427

Угадяров Л.А.	39	Шестов Д.А.	185
Углеv В.А.	413	Шубин И.В.	185
Фам К.Б.	65	Юрин А.Ю.	141
Харламов А.А.	80	Ярушкина Н.Г.	192
Цапенко И.В.	313	Ясир М.Д.	17
Царькова Е.Г.	88	Яхьяева Г.Э.	97

СОДЕРЖАНИЕ

СЕКЦИЯ 3. НЕЙРОСЕТЕВЫЕ, НЕЧЕТКИЕ МЕТОДЫ. МЯГКИЕ ИЗМЕРЕНИЯ И ВЫЧИСЛЕНИЯ

Викторов Е.А., Даниленко Г.О., Ковалев А.В. СВОЙСТВА ПАМЯТИ СИСТЕМЫ РЕЗЕРВУАРНЫХ ВЫЧИСЛЕНИЙ ПРИ ИЗМЕНЕНИИ ВРЕМЕНИ ВВОДА СИМВОЛОВ	8
Гладков Л.А., Ясир М.Д., Гладкова Н.В. ГИБРИДНЫЙ АЛГОРИТМ РЕШЕНИЯ ЗАДАЧИ РАЗМЕЩЕНИЯ ЭЛЕМЕНТОВ ЭВА.....	17
Иванов В.К., Палюх Б.В. ПРИМЕНЕНИЕ ТЕОРИИ СВИДЕТЕЛЬСТВ ДЛЯ ОБУЧЕНИЯ НЕЧЕТКИХ НЕЙРОННЫХ СЕТЕЙ ANFIS/TSK В ДИАГНОСТИЧЕСКИХ СИСТЕМАХ.....	27
Панов А.И., Угадяров Л.А. МОДЕЛЬ СРЕДЫ ДЛЯ АКТОРА И КРИТИКА В ОБУЧЕНИИ С ПОДКРЕПЛЕНИЕМ	39
Синюк В.Г., Каратач С.А. МЕТОД ВЫВОДА ДЛЯ СИСТЕМ ТИПА МАМДАНИ С НЕСИНГЛТОННОЙ ФАЗЗИФИКАЦИЕЙ.....	55
Фам К.Б., Мурашев П.М., Богатиков В.Н. ПРИМЕНЕНИЕ ОПТИМАЛЬНОГО АДАПТИВНОГО ОБОБЩЕННОГО ПРОГНОЗИРУЮЩЕГО УПРАВЛЕНИЯ К СУШКЕ ЗЕЛЕННОГО ЧАЯ.....	65
Харламов А.А., Бородин Н.С. ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ НА ОСНОВЕ НЕБИНАРНЫХ НЕЙРОНОВ С ВРЕМЕННОЙ СУММАЦИЕЙ СИГНАЛОВ В ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ	80
Царькова Е.Г. ДИНАМИЧЕСКАЯ МОДЕЛЬ ОПТИМАЛЬНОГО УПРАВЛЕНИЯ ОБУЧЕНИЕМ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ	88
Яхьяева Г.Э., Пальчунова О.Д. НЕЧЕТКИЕ МОДЕЛИ КАК ФОРМАЛИЗАЦИЯ ОЦЕНОЧНЫХ ЗНАНИЙ ЭКСПЕРТОВ.....	97

**СЕКЦИЯ 4. ПРИКЛАДНЫЕ ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ.
ИНСТРУМЕНТАЛЬНЫЕ СРЕДСТВА ПОСТРОЕНИЯ
ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ**

Виноградов Г.П. ИНТЕЛЛЕКТУАЛЬНЫЕ ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ В СОЕДИНЕНИЯХ ВООРУЖЕННЫХ СИЛ	110
Грибова В.В., Стрекалёв В.О. СЕМАНТИЧЕСКИЕ ТЕХНОЛОГИИ ДЛЯ РАЗРАБОТКИ ИММЕРСИВНЫХ ВИРТУАЛЬНЫХ СРЕД С БИОЛОГИЧЕСКОЙ ОБРАТНОЙ СВЯЗЬЮ	122
Гусакова С.М., Огорельцева Н.В. РАЗВИТИЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ПОДДЕРЖКИ НАУЧНЫХ ИССЛЕДОВАНИЙ В КРИМИНАЛИСТИКЕ	130
Дородных Н.О., Николайчук О.А., Юрин А.Ю. СОЗДАНИЕ ПРОТОТИПОВ ПРЕЦЕДЕНТНЫХ БАЗ ЗНАНИЙ НА ОСНОВЕ ТРАНСФОРМАЦИИ ТАБЛИЦ РЕШЕНИЙ ДЛЯ ПРОГНОЗИРОВАНИЯ РИСКА ЛЕСНЫХ ПОЖАРОВ	141
Котенко И.В., Левшун Д.А. ПРИМЕНЕНИЕ ИНТЕЛЛЕКТУАЛЬНЫХ МЕТОДОВ КОРРЕЛЯЦИИ СИСТЕМНЫХ СОБЫТИЙ В ПРОГНОЗНОЙ АНАЛИТИКЕ СОСТОЯНИЙ БЕЗОПАСНОСТИ ОБЪЕКТОВ КРИТИЧЕСКИ ВАЖНЫХ ИНФРАСТРУКТУР	152
Мазуров М.Е., Микрюков А.А. ИССЛЕДОВАНИЕ СЛАБОСТРУКТУРИРОВАННЫХ СОЦИАЛЬНО-ЭКОНОМИЧЕСКИХ СИСТЕМ НА ОСНОВЕ ГИБРИДНОЙ КОГНИТИВНОЙ КАРТЫ В КОМБИНАЦИИ С ИЗБИРАТЕЛЬНОЙ ДЕНДРИТНОЙ НЕЙРОСЕТЬЮ	168
Мохов А.С., Шестов Д.А., Шубин И.В. РАЗРАБОТКА СИСТЕМЫ ПО ДЕТЕКЦИИ НЕПРИГОДНОГО МРАМОРНОГО КАМНЯ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ	185
Мошкин В.С., Дырночкин А.А., Ярушкина Н.Г. АВТОМАТИЗАЦИЯ АНАЛИЗА ПРОГРАММНОГО КОДА С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ	192

Нагаева Д.З., Сазонова Е.Ю., Сметанина О.Н., Сазонов В.С. ТЕХНОЛОГИИ ИНЖЕНЕРИИ ЗНАНИЙ ПРИ ДИАГНОСТИКЕ ПИЩЕВОГО ПОВЕДЕНИЯ	205
Рыбина Г.В., Григорьев А.А. СОВРЕМЕННЫЕ АРХИТЕКТУРЫ ИНТЕЛЛЕКТУАЛЬНЫХ ОБУЧАЮЩИХ СИСТЕМ НА ОСНОВЕ ИНТЕГРИРОВАННЫХ ЭКСПЕРТНЫХ СИСТЕМ: ОСОБЕННОСТИ ПОДХОДА К АВТОМАТИЗИРОВАННОМУ ФОРМИРОВАНИЮ ОНТОЛОГИЧЕСКОГО ПРОСТРАНСТВА ЗНАНИЙ И УМЕНИЙ ОБУЧАЕМЫХ	218
Саенко И.Б., Котенко И.В., Аль-Барри М.Х. ИССЛЕДОВАНИЕ ВОЗМОЖНОСТЕЙ ВЫЯВЛЕНИЯ АНОМАЛЬНОГО ПОВЕДЕНИЯ ПОЛЬЗОВАТЕЛЕЙ ЦЕНТРОВ ОБРАБОТКИ ДАННЫХ НА ОСНОВЕ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ	232
Скрынников Н.С., Моросин О.Л. НЕЙРОСЕТЕВОЙ ПОДХОД К СТРУКТУРНО- СЕМАНТИЧЕСКОМУ АНАЛИЗУ ОЦИФРОВАННЫХ ДОКУМЕНТОВ	242
СЕКЦИЯ 5. ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ И УПРАВЛЕНИЯ	
Афанасьева Т.В., Платов П.В. СОЗДАНИЕ ЦИФРОВЫХ ПАЦИЕНТ-ОРИЕНТИРОВАННЫХ РЕКОМЕНДАЦИЙ НА ОСНОВЕ МНОГОУРОВНЕВОЙ ГРАНУЛЯЦИИ	251
Борисов В.В., Рязанов А.В., Бобряков А.В. МЕТОД ИНТЕЛЛЕКТУАЛЬНОЙ ПОДДЕРЖКИ ПРИНЯТИЯ ЛОГИСТИЧЕСКИХ РЕШЕНИЙ НА ОСНОВЕ ГЕНЕТИЧЕСКОЙ КЛАСТЕРИЗАЦИИ И НЕЧЕТКОГО МОДЕЛИРОВАНИЯ	265
Городецкий В.И. БАЗОВЫЕ ТРЕНДЫ ДЕЦЕНТРАЛИЗОВАННОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА	275

Грибова В.В., Ковалев Р.И., Окунь Д.Б. ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА НАЗНАЧЕНИЯ ПЕРСОНИФИЦИРОВАННОГО ЛЕЧЕНИЯ ПО АНАЛОГИИ	292
Добрынин Д.А. КОРРЕКЦИЯ ОШИБОК ПРИ ОБУЧЕНИИ В ЗАДАЧЕ УПРАВЛЕНИЯ ИНТЕЛЛЕКТУАЛЬНЫМ РОБОТОМ	302
Еремеев А.П., Колосов О.С., Зуева М.В., Цапенко И.В. ИНТЕГРАЦИЯ МЕТОДОВ СИСТЕМНОГО АНАЛИЗА И КОГНИТИВНОЙ ГРАФИКИ ПРИ РАННЕЙ ДИАГНОСТИКЕ ПАТОЛОГИЙ ЗРЕНИЯ	313
Зайцева Ю.С., Андриевский Б.Р. УПРАВЛЕНИЕ ВИБРАЦИОННОЙ МАШИНОЙ НА ОСНОВЕ ЭВРИСТИЧЕСКОГО АЛГОРИТМА	330
Колесников А.В., Корягин С.И., Либерман И.В., Клачек П.М., Бабкин А.В. ИНДУСТРИЯ 5.0: ОСНОВЫ СОЗДАНИЯ НЕЙРО-ЦИФРОВОГО ИНТЕЛЛЕКТА НА ПРИМЕРЕ КОМПАНИИ SPACEX.....	341
Колесников А.В., Мухитов Э.И. ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПО ТЕХНИЧЕСКОМУ ОБЕСПЕЧЕНИЮ ФЛОТА	351
Кулинич А.А. СЕМИОТИЧЕСКАЯ МОДЕЛЬ МЕНТАЛЬНОГО ПРОСТРАНСТВА.....	362
Микрюков А.А., Мазуров М.Е. КОГНИТИВНОЕ МОДЕЛИРОВАНИЕ ДЕЯТЕЛЬНОСТИ УНИВЕРСИТЕТА КАК СЛАБОСТРУКТУРИРОВАННОЙ СИСТЕМЫ	381
Румовская С.Б. ГИБРИДНЫЕ ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ ПЕРСОНАЛИЗИРОВАННОЙ ОЦЕНКИ СОСТОЯНИЯ СЛОЖНЫХ ОБЪЕКТОВ В МЕДИЦИНЕ С ПРИМЕНЕНИЕМ ДИНАМИЧЕСКОГО МОДЕЛИРОВАНИЯ ОБЪЕКТА ИССЛЕДОВАНИЯ	398

Углев В.А., Гаврилова Т.А.	
ПОДХОД К РЕАЛИЗАЦИИ СКВОЗНОЙ ВИЗУАЛЬНОЙ ПОДДЕРЖКИ ПРОЦЕССОВ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ ИНТЕЛЛЕКТУАЛЬНЫХ АВТОМАТИЗИРОВАННЫХ ОБУЧАЮЩИХ СИСТЕМ	413
Чернышев Л.С.	
СПОСОБ ОПТИМАЛЬНОГО УПРАВЛЕНИЯ ТЕХНИЧЕСКОЙ СИСТЕМОЙ ИЛИ ПРОЦЕССОМ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВОЙ МОДЕЛИ И АЛГОРИТМА ТОМПСОНОВСКОГО СЭМПЛИРОВАНИЯ	427
Abstracts of Sectional Reports	441
АВТОРСКИЙ УКАЗАТЕЛЬ	457

Научное издание

Двадцатая Национальная конференция
по искусственному интеллекту с международным участием
КИИ-2022

Труды конференции
Том 2

21–23 декабря 2022

Подписано в печать	30.11.22.	Печать ризография	Формат 60x84 1/16
Печ. л. 29,0	Тираж 90 экз.	Изд. № 22н-156	Заказ

Оригинал-макет подготовлен в РИО НИУ «МЭИ».
111250, г. Москва, ул. Красноказарменная, д. 14.
Отпечатано в типографии НИУ «МЭИ».
111250, г. Москва, ул. Красноказарменная, д. 13.