

УДК 004 891.3

doi: 10.15622/rcai.2025.089

ОБЪЕДИНЕНИЕ МУЛЬТИСЕНСОРНЫХ ДАННЫХ МНОГОСТАДИЙНОГО ПРОИЗВОДСТВА ДЛЯ ПРОГНОЗИРОВАНИЯ ОТКАЗОВ ТЕХНОЛОГИЧЕСКОГО ОБОРУДОВАНИЯ

А.Н. Ветров (*vetrov_48@mail.ru*)

Б.В. Палюх (*pboris@tstu.tver.ru*)

Тверской государственный технический университет, Тверь

В этой работе мы предлагаем новый подход, объединяющий мультисенсорные данные для обнаружения бифуркации многомерного случайного процесса, порождаемого работой технологического оборудования непрерывного многостадийного производства. В статье описана параметрическая многомерная модель обнаружения аномалий временного ряда, методика и процедура определения точки бифуркации. Рассмотрен метод скользящего окна для объединения мультисенсорных данных и их агрегация для регистрации аномалий в режиме реального времени.

Ключевые слова: объединение мультисенсорных данных, динамические экспертные системы, диагностика, точка бифуркации.

Введение

Мультисенсорное объединение данных (МСОД) – это технология, позволяющая объединять информацию из нескольких источников для формирования единой картины [Ciuonzo, 2014]. Технология МСОД отбирает полезную информацию от различных датчиков, использует определенные правила для объединения этой взаимной информации, чтобы обеспечить наиболее надежную и точную информацию для повышения эффективности системы. Объединение на уровне данных подразумевает интеграцию необработанных данных, получаемых от датчиков для получения агрегированной информации, необходимой для принятия решений. Объединение данных на уровне принятия решений, позволяет получать не только конкретную информацию, получаемую от датчиков. Этот способ обеспечивает лучшую интеграцию разнородных данных. Объединение данных для принятия решений хорошо сочетается с использованием байесовской

теории логического вывода, теории свидетельств Демпстера - Шафера, искусственных нейронных сетей и системы нечеткого логического вывода. В данной статье мы рассматриваем применение технологии МСОД для обнаружения аномалий во временных рядах, порождаемых потоками данных от сенсоров технологического оборудования [Paliukh, 2024], [Ветров, 2023].

Обнаружение аномалий во временных рядах связано с выявлением неожиданных изменений поведения системы для получения важной информации, сигнализирующей о дефектах в ней. Во многих промышленных приложениях обнаружение аномалий используется для мониторинга сбоев в работе технологического оборудования, оповещения пользователей о внешних атаках, обнаружения потенциальных катастрофических событий на ранней стадии. Несмотря на все прилагаемые усилия, разработка хорошего универсального алгоритма обнаружения аномалий является чрезвычайно сложной задачей. В последнее время для поиска аномалий во временных рядах успешно используются нейронные сети [Yangdong et al., 2019], [Su et al., 2019], [Zhao et al., 2020] [Zekai et al., 2021]. Одна из них VAE – Variational Autoencode [Dohyung et al, 2018]. VAE – это тип генеративной вероятностной модели, способной семплировать новые объекты, не принадлежащие исходным данным. Модель VAE была использована для обнаружения аномалий в различных областях с хорошими результатами [Lin et al, 2020]. Другая модель – LSTM. Это рекуррентные нейронные сети (RNN), способные эффективно работать с последовательными данными. Примеры использования моделей RNN для обнаружения аномалий приведены в [Yangdong et al., 2019], [Dan et al., 2019]. В работе [Malhotra, 2016] предложена гибридная модель, объединяющая модели VAE и LSTM.

В нашей работе мы использовали параметрическую модель векторной авторегрессии для автоматического обнаружения аномалий. Это обусловлено требованиями, которые предъявляются к системе обнаружения.

Основная часть этой статьи организована следующим образом: в разделе 1 обсуждается задача объединения мультисенсорных данных для обнаружения бифуркаций и требования к системе обнаружения. Основные определения, параметрическая многомерная модель обнаружения аномалий временного ряда, процедура объединения мультисенсорных данных для поиска точки бифуркации описаны в разделе 2. В разделе 3 рассматриваются метод скользящего окна для объединения мультисенсорных данных и их агрегация для регистрации аномалий в режиме реального времени. В заключении представлены полученные основные результаты.

1. Задача объединения мультисенсорных данных для обнаружения бифуркаций

Для многих промышленных предприятий обнаружение потенциально катастрофических событий на ранней стадии является актуальной проблемой. Для ее решения на базе информационных технологий и методов искусственного интеллекта нами была разработана динамическая экспертная система (ЭС) ExpSystem [Shabanov et al., 2019], [Palyukh et al., 2021], [Ветров, 2023]. Интеграционная схема программного комплекса представлена на рис. 1.

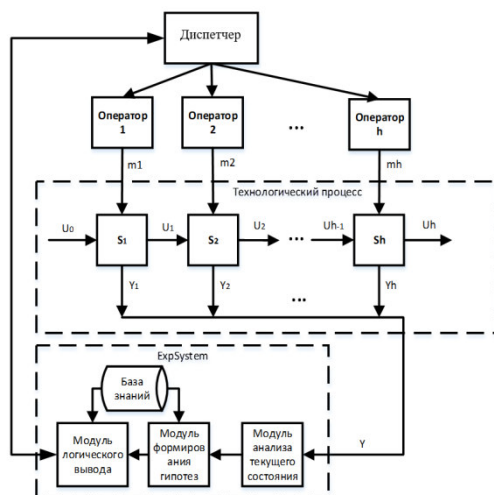


Рис. 1. Схема взаимодействия ЭС ExpSystem с системой управления многостадийным производством

Здесь использованы следующие обозначения: S_i – i -ая стадия многостадийного производства; U_i , Y_i – технологические параметры; m_i – управляющие воздействия. Система ориентирована на широкий класс технологических процессов, а именно на непрерывные многостадийные процессы. Особенность таких процессов заключается в том, что весь производственный процесс разбит на отдельные элементы – технологические стадии, которые связаны между собой непрерывными материальными потоками. Например, технологический процесс производства неконцентрированной азотной кислоты состоит из следующих основных стадий:

1. Подготовка и компримирование воздуха.
2. Подготовка газообразного аммиака.
3. Подготовка аммиачно-воздушной смеси.
4. Окисление аммиака и охлаждение нитрозных газов.

5. Абсорбция оксидов азота.

6. Селективная низкотемпературная каталитическая очистка хвостовых газов от оксидов азота и рекуперация энергии хвостовых газов в газовой турбине.

7. Хранение и выдача производственной кислоты.

На каждой стадии используется свое, специфическое оборудование, включающее множество различных агрегатов. Для того, чтобы контролировать состояние такого сложного процесса используются десятки показателей, которые называются технологическими параметрами. Обеспечение оперативного контроля, управление и защита процесса от аварийных ситуаций, сигнализация отклонений от номинальных режимов осуществляется с помощью автоматизированной системы управления технологическим процессом. В ее функции входит контроль режимов технологического процесса, измерение технологических параметров с помощью сенсоров, сбор данных, представление полученной информации о состоянии технологического объекта оперативно-технологическому персоналу.

Состояние технологического процесса оценивается на основе значений технологических параметров, измеряемых с определенной периодичностью. Анализ данных о состоянии процесса позволяет определить момент его перехода в критический режим. Индикатором перехода технологического процесса в критический режим служит аномальное динамическое поведение значений технологических параметров. Такое поведение есть следствие влияния на технологический процесс внешних и внутренних факторов. Например, неисправность или выход из строя оборудования, изменение характеристик поступающего в производство сырья и материалов. В экспертной системе ExpSystem заложена функция мониторинга значений технологических параметров. Анализ их значений является основой для раннего предупреждения дефектов, отказов и аварий.

При работе технологического оборудования в штатном режиме порождаемый им случайный процесс изменения технологических параметров является стационарным с математическим ожиданием не зависящим от времени. Его колебания обусловлены шумами и имеют ограниченный характер.

Причиной появления аномалий во временном ряду является переходный процесс, который возникает в системе как следствие влияния внешних и внутренних факторов на работу технологического оборудования. Таким образом стационарный процесс переходит в нестационарный. Наличие тренда в нестационарном процессе является причиной перехода системы в предаварийный режим. Определение момента начала переходного процесса (точки бифуркации) и выявление тренда по отдельным временным рядам с помощью метода двойного скользящего окна описано в нашей работе [Paliukh, 2024]. На самом деле наблюдаемый случайный процесс является многомерным и отдельные его компоненты коррелированы между собой.

Учет взаимосвязи компонент многомерного случайного процесса делает соответствующие оценки в определении точки бифуркации более достоверными и снижают вероятность возникновения ложной тревоги.

Кроме того, анализ многомерных временных рядов поможет выявить кластеры связанных технологических показателей. В дальнейшем это позволит уточнить причину возникшей аномалии.

В данной работе решается задача объединения мультисенсорных данных для прогнозирования бифуркаций и определения взаимосвязи между технологическими показателями.

Исходя из вышеизложенного можно сформулировать минимальные требования к выбору метода решения поставленной задачи:

- 1) необходимо учитывать тот факт, что процесс нестационарный;
- 2) необходимо обрабатывать данные в режиме реального времени без предварительного обучения;
- 3) необходимо учитывать объединенную информацию от всех сенсоров;
- 4) необходима получать результат в ограниченные сроки.

2. Параметрическая многомерная модель обнаружения аномалий временного ряда

Контроль состояния производственного процесса осуществляется на основании дискретной последовательности измеренных значений множества технологических параметров. Эти последовательности образуют бесконечные многомерные временные ряды (МВР). Все измеренные значения являются отражением (реализаций) многомерного случайного процесса (МСП).

Будем обозначать его как вектор $Y(t) = (Y_1(t), ..., Y_i(t), ..., Y_m(t))^T$, где m соответствует числу сенсоров технологического оборудования. Каждому сенсору соответствует один технологический параметр. Будем обозначать временной ряд, порождаемый случайным процессом $Y_i(t)$ как бесконечная последовательность $y_i(t_1), y_i(t_2), ..., y_i(t_k), ...$ значений технологического параметра, поступающих от i -го сенсора в дискретные моменты времени t_k . Обозначим $y_i(t) = (y_i(t_1), y_i(t_2), ..., y_i(t_N))^T$ вектор, содержащий конечный набор значений технологического параметра, зарегистрированный i -м сенсором. Для описания многомерных временных рядов будем использовать вектор $Y_t = (y_{1t}, ..., y_{it}, ..., y_{mt})^T$. Математическое ожидание стационарного МСП $M[Y] = (\mu_1, ..., \mu_i, ..., \mu_m)^T$ не зависит от времени, в то время как математическое ожидание нестационарного МСП $M[Y(t) = (\mu_1(t), ..., \mu_i(t), ..., \mu_m(t))^T]$ есть функция времени. Для анализа взаимосвязи многомерных случайных процессов используются автокорреляционная функция (АФ) $R_{Y_i}(t_1, t_2) = M[\dot{Y}_i(t_1)\dot{Y}_i(t_2)]$ и взаимная корреляционная функция (ВКФ)

$R_{Y_i Y_j}(t_1, t_2) = M[\dot{Y}_i(t_1)\dot{Y}_j(t_2)]$. Здесь $\dot{Y} = Y - M[Y]$. Если процесс стационарный, значения АФ и ВКФ зависят не от моментов времени t_1, t_2 , а от их разницы $t_2 - t_1 = \tau$. Тогда АФ $R_{Y_i}(t_1, t_2) = R_{Y_i}(\tau) = M[\dot{Y}_i(t_1)\dot{Y}_i(t_1 + \tau)]$ и ВКФ $R_{Y_i Y_j}(t_1, t_2) = R_{Y_i Y_j}(\tau) = M[\dot{Y}_i(t_1)\dot{Y}_j(t_1 + \tau)]$. Как уже было отмечено, при работе технологического оборудования в штатном режиме, порождаемый им МСП является стационарным, что подтверждено проведенными исследованиями. Кроме того, МСП является эргодическим. Это позволяет вычислять оценки характеристик стационарного МСП на основе одной единственной реализации путем усреднения значений временных рядов по времени.

В отличие от стационарного процесса соответствующие характеристики нестационарного МСП являются функциями времени. Для вычисления оценок характеристик нестационарного МСП требуется усреднение значений временного ряда по ансамблю, поскольку многомерный закон распределения случайной величины в каждом временном сечении разный. Полученные по единственной реализации оценки в случае нестационарного случайного процесса будут недостоверными (смещенными, несостоятельными и неэффективными).

В такой ситуации параметрическое представление МВР является эффективной альтернативой классическому корреляционному описанию. Для обнаружения аномалий в МВР и определения точки бифуркации мы используем модель векторной авторегрессии.

Для того, чтобы учесть взаимную зависимость компонент случайного процесса выразим каждое значение временного ряда $y_i(t)$ в виде линейной комбинации остальных, т.е. $y_1(t), \dots, y_{i-1}(t), y_{i+1}(t), \dots, y_m(t)$, и их значений, сдвинутых на величину τ . Сдвиг τ принимает целочисленные значения от 1 до p . Таким образом мы имеем систему n линейных уравнений. Модель векторной авторегрессии имеет вид:

$$Y_t = B_1 Y_{t-1} + B_2 Y_{t-2} + \dots + B_p Y_{t-p} + \varepsilon_t. \quad (1)$$

Здесь использованы следующие обозначения. Вектор текущих значений временного ряда $Y_t = (y_{1t}, \dots, y_{it}, \dots, y_{mt})^T$. Векторы значений МВР, сдвинутых на величину $\tau - Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$. Соответственно имеем $Y_{t-1} = (y_{1-t-1}, \dots, y_{it-1}, \dots, y_{mt-1})^T$, $Y_{t-2} = (y_{1-t-2}, \dots, y_{it-2}, \dots, y_{mt-2})^T, \dots, Y_{t-p} = (y_{1-t-p}, \dots, y_{it-p}, \dots, y_{mt-p})^T$.

B_1, B_2, \dots, B_p – матрицы коэффициентов векторов значений МВР, сдвинутых на величину τ . Произвольная матрица B_l содержит компоненты

$$B_l = \begin{pmatrix} b_{1l}^1 & b_{2l}^1 & \dots & b_{ml}^1 \\ b_{1l}^2 & b_{2l}^2 & \dots & b_{ml}^2 \\ \dots & \dots & \dots & \dots \\ b_{1l}^m & b_{2l}^m & \dots & b_{ml}^m \end{pmatrix}. \quad (2)$$

Вектор случайных компонент ε_t имеет вид $\varepsilon_t = (\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{mt})^T$. Компоненты вектора, независимы имеют нулевое математическое ожидание и постоянную дисперсию. Используя параметрическую многомерную модель случайного процесса (1) сформулируем условия для определения точки бифуркации. Предварительно, используя оператор сдвига $Hy_t = y_{t-1}$, преобразуем выражение (1). В результате получим тождественное (1) выражение $(I - B_1H + B_2H^2 + \dots + B_mH^m)y_t = \varepsilon_t$.

Здесь I – единичная матрица $m \times m$, вида

$$\begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \dots & \dots & \ddots & \dots \\ 0 & \dots & \dots & 1 \end{pmatrix}$$

Рассмотрим характеристическое уравнение

$$\Phi(H) = I - B_1H + B_2H^2 + \dots + B_mH^m = 0, \quad (3)$$

где $\Phi(H)$ – квадратная матрица $m \times m$.

Корни характеристического уравнения, действительные и комплексно-сопряженные, можно вычислить как собственные числа матрицы $\Phi(H)$. Обозначим их $\lambda_1, \lambda_2, \dots, \lambda_i, \dots, \lambda_m$. Если выполняются условия

$$\lambda_1 \neq \lambda_2 \neq \dots \neq \lambda_i \neq \dots \neq \lambda_m \text{ и } |\lambda_i| > 0 \quad \forall i, \quad (4)$$

то рассматриваемый многомерный случайный процесс является стационарным. Определим точку бифуркации t_0 , как момент времени, в котором зафиксирован переход случайного процесса из стационарного состояния в нестационарное. Определим $\delta_Y(t)$ индикаторную функцию, указывающую на смену характера случайного процесса в момент времени, t следующим образом

$$\delta_Y(t) = \begin{cases} 0 & \text{если } t < t_0 \mid |\lambda_i| > 0 \quad \forall i \\ 1 & \text{если } t < t_0 \mid |\lambda_i| \leq 0 \quad \exists i \end{cases}. \quad (5)$$

Значение $\delta_Y(t) = 0$ указывает на то, что процесс стационарный – выполняются условия стационарности (4). Значение $\delta_Y(t)$ равное 1, предполагает, что не для всех компонент МВР выполняются условия стационар-

ности (4). Таким образом, значение $\delta_Y(t)=1$ указывает на то, что случайный процесс носит нестационарный характер. Те значения собственных чисел λ_i , для которых условия стационарности нарушены, указывают на технологические параметры, значения которых выходят за пределы нормативных значений. Обозначим $K(t_0) = \{i \in \overline{1, m} : |\lambda_i| < 0\}$ множество номеров сенсоров и связанных с ними технологических параметров, которые указывают на нарушение штатного режима функционирования технологического оборудования.

После того, как был установлен факт нарушения технологического режима и выявлены технологические параметры, указывающие на нарушение штатного режима работы производственного оборудования, необходимо определить связи между этими параметрами. Для этого будем использовать временные ряды, которые формируются сенсорами с номерами $i \in K(t_0)$. Поскольку процесс нестационарный, использование традиционного корреляционного или спектрального анализа мало информативно. Для анализа связи между временными рядами будем проверять наличие коинтегрированности между ними. Для этого используем параметрическую многомерную модель, подобную модели (1), исключив из рассмотрения стационарные компоненты. Преобразуем каждую из оставшихся компонент к стационарному виду путем взятия конечных разностей. Обозначим Δ – конечная разность порядка d для временного ряда y_{it} , $i \in K(t_0)$. Определим коинтеграцию между временными рядами с индексами i и j , $i, j \in K(t_0)$. Параметрическая модель имеет вид

$$\begin{aligned}\Delta y_{it} &= a_{11}^1 \Delta y_{it-1} + \dots + a_{1p}^1 \Delta y_{it-p} + a_{21}^1 \Delta y_{it-1} + \dots + a_{2p}^1 \Delta y_{it-p} + \varepsilon_{1t}, \\ \Delta y_{jt} &= a_{11}^2 \Delta y_{it-1} + \dots + a_{1p}^2 \Delta y_{it-p} + a_{21}^2 \Delta y_{jt-1} + \dots + a_{2p}^2 \Delta y_{jt-p} + \varepsilon_{2t},\end{aligned}$$

Представим эту модель в общем виде

$$\Delta Y_t = A_1 \Delta Y_{t-1} + A_2 \Delta Y_{t-2} + \dots + A_p \Delta Y_{t-p} + \varepsilon_{1t}.$$

Проверим модель на стационарность так, как было описано выше. Если корни матрицы $\Phi(H)$ $|\lambda_1| > 1$ и $|\lambda_2| > 1$, то коинтеграция между временными рядами y_{it} и y_{jt} отсутствует. В противном случае эти ряды коинтегрированы. Это означает, что между ними существует некая зависимость, которая определяет их общее поведение.

3. Скользящее окно для объединения мультисенсорных данных

Для проверки условий стационарности на основе конечного набора данных, поступающих непрерывно от сенсоров технологического оборудования применяется потоковая обработка, включающая агрегацию ин-

формации с использованием скользящих окон. Данные в бесконечном потоке фиксируются скользящим окном и агрегируются по мере того, как элементы данных вставляются и удаляются из скользящего окна. Скользящее окно строится на основе кортежей над бесконечным потоком $S - S_H[H_L, H_R]$, где $H_L > H_R$ любые два неотрицательных целых числа, определяющие левую и правую границы окна. Когда текущая длина потока равняется H , скользящее окно $S_H[H_L, H_R]$ содержит набор кортежей $\{y_j: \{(H - H_L + 1) \leq j \leq (H + H_R - 1)\}\}$. С течением времени состояние скользящего окна меняется. Обозначим k – номер состояния, целое положительное число. Значения левой и правой границ скользящего окна меняются при изменении состояния окна. Состояние скользящего окна определяется набором кортежей, входящих в него. Обозначим O_1, \dots, O_n набор операторов агрегации. Для входного потока S $O_j = f_A(S_H[H_L, H_R])$, где f – функция агрегации, а A – атрибут агрегации. Каждое значение атрибута агрегации a_i представляет собой элемент потока. В процессе обработки потоковых данных соответствующие значения элементов потока записываются в циклический буфер и обрабатываются операторами агрегации O_j , а результат агрегации сохраняется в памяти. Рассматриваемый метод двойного скользящего окна предполагает использование системы агрегации, состоящей из двух скользящих окон для каждого сенсора технологического оборудования. Первое скользящее окно W_1^i используется как низкочастотный фильтр, подавляющий кратковременные случайные выбросы значений технологических параметров. Здесь i – номер сенсора $i = \overline{1, m}$. Второе скользящее окно W_2^i аккумулирует информацию для анализа состояния технологического процесса и определение точки бифуркации. Текущее состояние скользящего окна W_1^i определяется набором кортежей, хранящихся в циклическом буфере окна W_1^i в данный момент. Текущее состояние скользящего окна W_2^i определяется набором агрегированных значений, вычисленных в окне W_1^i .

Укрупненный алгоритм обработки потоковых данных содержит следующие шаги.

1. Считываем текущее состояние скользящего окна W_1^i из циклического буфера. $I_k^i = \{y_j \in S_H^i(H_{Lk}^i, H_{Rk}^i)\}$.
2. Вычисляем N значений агрегата $f_A(I_k^i)$ для всех элементов потока, соответствующих текущему состоянию k скользящего окна W_1^i .

3. Добавляем все вычисленные значения $f_A(I_k^i)$ в окно W_2^i . Обозначим эти значения $f_1^i, f_2^i, \dots, f_N^i$. Они определяют текущее состояние скользящего окна W_2^i .
4. Формируем объединенную матрицу исходных данных для расчета коэффициентов модели (1). Для этого считываем данные текущего состояния всех скользящих окон W_2^i из циклических буферов. Вычисляем коэффициенты векторной авторегрессии (1), соответствующие текущему состоянию всех скользящих окон W_2^i .
5. Решаем характеристическое уравнение (3). Если корни характеристического уравнения не удовлетворяют условию (4), индикаторная функция (4) принимает значение 1. Точка бифуркации соответствует моменту получения индикаторной функцией значения, равного единице, в реальном времени. Процесс поиска аномалий заканчивается. Если корни характеристического уравнения соответствуют условию (4), индикаторная функция принимает значение 0. Процесс поиска аномалий продолжается.
6. Продолжаем проверку условия (4). Удаляем значения “самого старого” интервала из окна W_1^i .
7. Добавляем значения следующего интервала в окно W_1^i .
8. Вычисляем значения $f_A(I_k)$ для последнего добавленного интервала.
9. Добавляем последнее вычисленное значения $f_A(I_k)$ в окно W_2^i .
10. Удаляем значения “самого старого” значения агрегата из окна W_2^i .
11. Возвращаемся на шаг 1.

Процедура обработки данных останавливается внешним прерыванием.

4. Результат апробации методики

Предложенная методика была апробирована на производстве неконцентрированной азотной кислоты. В течении 2 лет был проведен детальный анализ работы агрегата УКЛ-7, включающий сбор данных для дальнейшего исследования и проверки эффективности программного комплекса и разработанной методики, направленной на повышение эксплуатационной надежности оборудования. На основе этих данных была рассчитана вероятность безотказной работы многостадийного производства (табл. 1).

Таблица 1

Изменение показателя вероятности безотказной работы многостадийного производства

	Вероятность безотказной работы многостадийного производства	Вероятность отказа многостадийного производства
До внедрения	0,9868	0,0132
После внедрения	0,9882	0,0118
Улучшение показателя в %		~10,6%

Таким образом, применение предложенной методики позволило повысить эксплуатационную надежность многостадийного производства за рассматриваемый период на ~10,6%.

Заключение

В статье представлен новый подход объединяющий мультисенсорные данные для обнаружения бифуркации многомерного случайного процесса, порождаемого работой технологического оборудования непрерывного многостадийного производства. Достоинство этого подхода заключается в том, что в отличие от существующих разработок предлагаемая система детектирования бифуркаций не требует предварительного обучения. Обнаружение аномалий в технологическом процессе происходит on-line на основе анализа бесконечного многомерного потока технологических данных, получаемых от сенсоров оборудования. Проведенные испытания подтвердили эффективность предложенной методики детектирования бифуркаций.

Полученные результаты могут служить методологической основой для разработки динамической экспертной системы, работающей в режиме реального времени для прогнозирования отказов технологического оборудования непрерывного многостадийного производства.

Список литературы

- [Ветров, 2023] Ветров А.Н., Мальков, А.А., Палюх Б.В. Детектирование бифуркаций многомерных случайных процессов в динамических экспертных системах // Двадцать первая Национальная конференция по искусственному интеллекту с международным участием, КИИ-2023 (Смоленск, 15-20 октября 2023 г.): Труды конференции. В 2-х т. Т. 2. – С. 173-182.
- [Ciunzo, 2014] Ciunzo D., Salvo Rossi P. Decision Fusion with Unknown Sensor Detection Probability // IEEE Signal Processing Letters. – 21 (2). – P. 208-212. – doi: 10.1109/LSP.2013.2295054.

- [**Dan et al, 2019**] Dan Li, Dacheng Chen, Baihong Jin, Lei Shi, Jonathan Goh, and Sec-Kiong Ng. MAD-GAN: Multivariate anomaly detection for time series data with generative adversarial networks // In Artificial Neural Networks and Machine Learning: Text and Time Series. – 2019. – P. 703-716.
- [**Dohyung et al, 2018**] Dohyung Kim, Hyochang Yang, Minki Chung, Sungzoon Cho, Huijung Kim, Minhee Kim, Kyungwon Kim, and Eunseok Kim. Squeezed convolutional variational autoencoder for unsupervised anomaly detection in edge device industrial internet of things // In International Conference on Information and Computer Technologies. – 2018. – P. 67-71.
- [**Malhotra, 2016**] Malhotra P., Ramakrishnan A. LSTM-based encoder-decoder for multi-sensor anomaly detection. Available: arXiv:1607.00148 [cs.AI]. – 2016.
- [**Palyukh et al, 2021**] Palyukh B., Merkurjev S., Vetrov A., Shabanov B. and Sotnikov A. Methods for Forecasting Critical States of the Technological Process in the Evolutionary Management of Continuous Multi-Stage Production // 2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus). – 2021. – DOI: 10.1109/ElConRus51938.2021.9396111.
- [**Paliukh, 2024**] Paliukh B.V., Malkov A.A., Vetrov A.N. Bifurcation Detections of Multidimensional Random Processes in Dynamic Expert Systems // PATTERN RECOGNITION AND IMAGE ANALYSIS. – Vol. 34, Issue 3. – P. 751-756. – DOI: 10.1134/S1054661824700627.
- [**Shabanov et al, 2019**] Shabanov B., Sotnikov A., Palyukh B., Vetrov A., Alexandrova D. Expert System for Managing Policy of Technological Security in Uncertainty Conditions: Architectural, Algorithmic, and Computing Aspects // Proceedings of the 2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus) January 28-30, 2019.
- [**Lin et al, 2020**] Lin Shuyu, Clark Ronald, Birke Robert, Schonborn Sandro, Trigoni Niki, Roberts Stephen. Anomaly detection for time series using vae-lstm hybrid model. ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). – DOI: 10.1109/ICASSP40776.2020.9053558.
- [**Su et al, 2019**] Su Y., Zhao Y., Niu C., Liu R., Sun W., and Pei D. Robust anomaly detection for multivariate time series through stochastic recurrent neural network // In ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. – 2019. – P. 2828-2837.
- [**Yangdong et al, 2019**] Yangdong He and Jiabao Zhao. Temporal convolutional networks for anomaly detection in time series // Journal of Physics: Conference Series. – 2019. – 1213(4).
- [**Zekai et al, 2021**] Zekai Chen, Dingshuo Chen, Zixuan Yuan, Xiuzhen Cheng, and Xiao Zhang. Learning graph structures with transformer for multivariate time series anomaly detection in IoT. ArXiv, abs/2104.03466, 2021.
- [**Zhao et al, 2020**] Zhao H., Wang Y., Duan J., Huang C., Cao D., Tong Y., Xu B., Bai J., Tong J., and Zhang Q. Multivariate time-series anomaly detection via graph attention network // In 20th IEEE International Conference on Data Mining. – 2020. – P. 841-850.