

УДК 004.896

doi: 10.15622/rcai.2025.076

ВЫЯВЛЕНИЕ АНОМАЛИЙ В ФИНАНСОВЫХ ВРЕМЕННЫХ РЯДАХ НА ОСНОВЕ МНОГОМАСШТАБНОГО АВТОКОДИРОВЩИКА¹

А.Ю. Пучков (*putchkov63@mail.ru*)^A

В.С. Минин (*Mininvssm@yahoo.com*)^B

^A Филиал Национального исследовательского университета «МЭИ»

в г. Смоленске, Смоленск

^B ООО «ВИСОМ», Смоленск

Предложен метод выявления аномалий в финансовых временных рядах, данные в которых отображены с различными интервалами дискретизации по времени. Новизна метода заключается в применении многомасштабного автокодировщика, на вход которого подается расширенный набор данных, включающий как значения самого временного ряда с различной временной дискретизацией, так и их первые и вторые разности. Проведенные модельные эксперименты показали, что такое расширение увеличивает ошибку автокодировщика при восстановлении входных данных с аномалиями, по сравнению с ошибкой автокодировщика без такого расширения.

Ключевые слова: выявление аномалий в данных, финансовые временные ряды, искусственные нейронные сети, автокодировщик.

Введение

В трейдинге важно вовремя реагировать не только на краткосрочные изменения котировок валют, акций, объемов торгов, разнообразных биржевых и внебиржевых инструментов, но и на более сложные и долговременные тенденции развития фондовых рынков. Перечисленные характеристики торгов (с привязкой ко времени их фиксации) отображаются в виде финансовых временных рядов. Они имеют свою специфику, не позволяющую найти единственно верный и работающий метод анализа и прогнозирования [Зиненко, 2023]. Однако результаты такого анализа представляет интерес для инвесторов-практиков, особенно в условиях развития цифровых финансов и нестабильности мировых рынков [Verma, 2024].

¹ Работа выполнена при финансовой поддержке РФФ (проект № 22-61-00096).

Алгоритмическая биржевая торговля сейчас представляет собой основной продуктом финансового рынка, так как подавляющее количество сделок полностью автоматизированы. Поэтому в алгоритмическое обеспечение торговых роботов (специальных программ, автоматизирующих биржевую торговлю) включается широкий спектр методов – начиная от классических статистических и заканчивая методами искусственного интеллекта [Pricope, 2021], [Chahuan-Jimenez, 2024], [Dorfeshan, 2022].

Одна из задач анализа финансовых временных рядов – обнаружение аномалий в данных (Anomaly detection, AD). Методы AD хорошо себя зарекомендовали при обнаружения подозрительной активности в финансовых транзакциях, потенциально сигнализирующих об отмывании денег [Gadimov, 2025].

В связи с этим разработка новых методов и алгоритмов AD в финансовых временных рядах представляет собой актуальную исследовательскую задачу, решение которой позволяет инвесторам обоснованно подходить к выбору стратегий торговли – от высокочастотного трейдинга (High Frequency Trading, HFT) до долгосрочных инвестиций в сбалансированные портфели биржевых инструментов, а торговым роботам повышать эффективность принимаемых решений.

К наиболее востребованным задачам анализа финансовых временных рядов относятся задачи прогнозирования и выявления аномалий в данных временного ряда, причем решение последней представляет особый интерес, так как позволяет своевременно выявлять недобросовестное поведение участников торгов, проявление неконтролируемых тенденций, событий.

Целью представляемого исследования являлась разработка метода выявления аномалий в финансовых временных рядах на основе применения искусственных нейронных сетей для анализа котировок биржевых инструментов, представленных с различной временной дискретизацией.

В процессе исследования был проведен обзор существующих методов выявления аномалий в финансовых временных рядах с указанием их ограничений, разработаны архитектура нейронной сети и метод ее применения для выявления аномалий в финансовых данных, проведены численные эксперименты для апробирования предложенного метода.

1. Методы выявления аномалий во временных рядах на фондовом рынке

После представления биржевых котировок на фондовом рынке в виде временного ряда задачи его анализа могут быть формализованы (абстрагированы от предметной области) и решаться с применением представления ряда как во временной, так и частотной областях методами машинного обучения [Прогнозирование, 2016a], [Sakib, 2025].

Под аномалией в данных понимается отклонение значений временного ряда от характерных для него. В зависимости от вида искомым аномалий (точечные, коллективные, аномалии контекста) выбираются методы их выявления, которые можно разделить на статистические, контролируемые, полуконтролируемые и неконтролируемые.

Статистические методы позволяют отслеживать лишь такие типовые характеристик временных рядов, как период, сезонность, циклы, тренд, корреляцию, поэтому они сейчас не входят в популярные инструменты новых методов выявления аномалий. Более глубокие закономерности в рядах способны выявлять модели нейросетевого неконтролируемого обнаружение аномалий, что важно во многих приложениях, включая финансовую аналитику, обнаружение кибервторжений, медицинскую диагностику [Sefati, 2025].

Аномалии временного ряда, в частности, выбросы, приводят к расширению возможного диапазона его значений, что используется в подходах к выявлению аномалий на основе методов интервального анализа. Так, в [Калмыков, 1986] представлены интервальные аналоги интерполяционных формул Лагранжа, Ньютона, Эрмита, применение которых для выявления аномалий в данных основывается на возрастании ошибки восстановления значений временного ряда по сравнению с нормальными данными, для описания которых формировались интервальные оценки. В случае различных интервалов дискретизации компонент временного ряда возможно применение обобщенных интервальных оценок [Стернин, 2005]. Однако интервальные подходы требуют затрат на формирование исходного описания данных в терминах интервального анализа, что повышает их трудоемкость. Поэтому методы на основе машинного обучения, автоматизирующие процесс получения моделей, сейчас находят наибольшее применение в прикладных задачах выявления аномалий в данных. Анализ эффективности различных моделей машинного обучения при выявлении аномалий в финансовых данных показывает, что модели обеспечивают дополнительную ежемесячную доходность около двух процентов [Azevedo, 2023].

Неконтролируемое обнаружение аномалий с успехом реализуется с применением архитектуры автокодировщика (Autoencoder, AE) – специального вида нейронных сетей, принцип работы которых состоит в получении на выходном слое данных, наиболее близких к входному. Это обстоятельство положено в основу обнаружения аномалий – если AE «видит» на входе знакомые данные (близкие к тем, на которых он обучался), то ошибка воспроизведения этих данных на выходе AE будет небольшая, в противном случае, если данные аномальные, ошибка будет больше, чем обычно и можно говорить об аномальности входных данных. Для исключения тривиального решения в архитектуре AE один из промежуточных

слоев имеет меньшую размерность, чем входной и выходной слою, что заставляет АЕ выявлять наиболее значимые паттерны в данных для генерации выходных данных.

Применение АЕ для выявления аномалий в финансовых данных представлено широко. Так, в [Long, 2025a] представлен АЕ на основе сети LSTM (Long Short-Term Memory), который учитывает структуру финансовых рынков и демонстрирует способность выявлять финансовые кризисы. Для этого применяется визуализация матрицы весов LSTM на тепловой карте – большее преобладание ярких цветов по сравнению с темными цветами, по мнению авторов свидетельствует о кризисных явлениях.

Идентификация аномальных колебаний цен на сельскохозяйственную продукцию с использованием сверточной нейронной сети (Convolutional Neural Network, CNN) описана в [Time, 2023a]. В этой работе изображения временных рядов (Time Series Images, TSI) классифицируются CNN. Для преобразования разреженного одномерного временного ряда цен на сельскохозяйственную продукцию в TSI применяется поле перехода Маркова (Markov Transition Field, MTF). CNN автоматически извлекает признаки из TSI, разделенные на две категории: «нормальные» и «аномальные». По заверениям авторов такая структура выявления аномалий обеспечивает точность, в среднем на 20% выше по сравнению с другими методами оценки аномальных колебаний.

Более обширный обзор архитектур и перспектив применения АЕ представлен в [Mienye, 2025].

Анализ моделей выявления аномалий в финансовых временных рядах показал, что в своем большинстве они используют данные с одним и тем же масштабом времени (временное окно одного размера), а интервал временной дискретизации постоянен. Однако, если смотреть статистику котировок, то она обычно доступна с различной временной дискретностью. Например, на сайте ProFinance котировки биржевых инструментов можно получить с дискретностью 1, 3, 5, 15 минут, 1, 2, 4 часа, один день, одна неделя. Соответственно, рассматривая краткосрочное окно данных невозможно определить аномалию, присущую более длительным временным интервалам, которая, в конечном итоге, будет сказываться и на более краткосрочных временных промежутках.

Аналогичный вывод делается в работе [A Multi-scale, 2024], где отмечается, что окно данных фиксированной длины затрудняет одновременное обнаружение как точечных аномалий, так и крупномасштабных контекстных. Там же предлагается модель с двумя АЕ, использующими механизм внимания, для изучения закономерностей временных рядов в разных масштабах и отмечается, что она превосходит большинство существующих моделей.

Еще один вариант модели многомасштабного неконтролируемого обнаружения аномалий в многомерных временных рядах представлен в [Probabilistic, 2023a], где применяется вероятностный АЕ. Отмечается, что эксперименты с моделью на реальных наборах данных показали метрику $F1$, превосходящую современные модели выявления аномалий в данных.

Однако и в этих исследованиях анализируются только сами значения временного ряда, в то время как дополнительные характеристики, такие как первые и вторые разности, отнесенные к соответствующим интервалам дискретизации (аналоги скорости и ускорения в кинематике), как несложный результат процедуры конструирования признаков (Feature Engineering, FE), могут дать дополнительные возможности для повышения качества модели выявления аномалий в финансовых временных рядах.

2. Постановка задачи выявления аномалий в данных

Пусть доступны данные о котировках различных биржевых инструментов, представленные с различной дискретизацией по времени. Эти данные сгруппированы в матрицы D_i , $i=1, 2, \dots, N$, где N – количество биржевых инструментов. Вся совокупность данных сгруппирована в матрицу $D=\{D_i\}$. Предполагается, что данные в D являются «нормальными», то есть не аномальными.

Каждая из матриц D_i содержит K строк, где K – количество различных значений интервалов дискретизации по времени, представленные в данных о котировках. Другими словами, k -я строка матрицы D_i – это значения котировок i -го биржевого инструмента для интервала дискретизации Δt . В результате матрица имеет структуру: $D_i = \{D_{i,1}; D_{i,2}; \dots, D_{i,k}; \dots, D_{i,K}\}$, где «;» обозначает переход на новую строку. Предполагается, что $K = const$. Таким образом, длина k -й строки в D равна количеству дискретных котировок J_k для k -го интервала дискретизации, а общее количество строк равно K .

Чтобы не увеличивать размерность матриц $D_{i,k}$ за счет добавления временной оси, фиксирующей моменты получения котировок, формируется вектор интервалов дискретизации $\Delta T = \{\Delta t_k\}$. На его основе, при заданном порядковом номере котировки j и Δt всегда можно определить дискретный момент времени $t_j = j\Delta t_k$, где $j=0, 1, 2, \dots, J_k$, где J_k – количество дискретных котировок для k -го интервала дискретизации.

Ставится задача разработки метода выявления коллективных (групповых) аномалий в новых данных, то есть, не представленных на временных интервалах, для которых сформирована матрица D . При этом отдельно не оговариваются особенности аномалий, которые могли бы дать о них дополнительную информацию. Конкретизация задачи по поводу коллективных аномалий снимает необходимость выявления выбросов, для которых разработано множество методов, учитывающих особенности их проявления [Pehlivan, 2024].

3. Метод решения

Включение дополнительных признаков, извлекаемых из имеющихся временных рядов на этапе препроцессинга, может повышать точность модели AD [de Jesus, 2025]. В предлагаемом методе решения поставленной задачи для выявления аномалий в финансовых рядах процедура FE заключается в формировании на основе матрицы D расширенного набора данных – матрицы DM , содержащей дискретные аналоги первой и второй производной котировок по времени.

Для i -го биржевого инструмента и для интервала дискретизации Δt одна строка $D_{i,k}$ матрицы D_i модифицируется в три строки:

$$DM_{i,k} = \begin{pmatrix} (D_{i,k})_1 & (D_{i,k})_2 & \dots & (D_{i,k})_{J_k} \\ (\Delta D_{i,k} / \Delta t_k)_1 & (\Delta D_{i,k} / \Delta t_k)_2 & \dots & (\Delta D_{i,k} / \Delta t_k)_{J_k} \\ (\Delta^2 D_{i,2} / \Delta t_k^2)_1 & (\Delta^2 D_{i,2} / \Delta t_k^2)_2 & \dots & (\Delta^2 D_{i,2} / \Delta t_k^2)_{J_k} \end{pmatrix}, \quad (3.1)$$

где $\Delta D_{i,k} / \Delta t_k$ – «скорость» изменения котировок i -го биржевого инструмента; $\Delta^2 D_{i,k} / \Delta t_k^2$ – «ускорение».

В результате применения (3.1) ко всем строкам D будет получена расширенная матрица $DM = \{DM_{i,k}\}$, содержащая $3NK$ строк.

Учитывая, что если $\Delta t_{k+1} > \Delta t_k$ то, J_{k+1} не совпадает с J_k . и в этом случае количество элементов в разных строках D будет разное. Это будет затруднять подготовку обучающих наборов данных для модели машинного обучения. Для исключения этой ситуации в процессе FE также проводится выравнивание количества элементов в строках с помощью тривиальной процедуры – заполнения $\Delta t_{k+1} / \Delta t_k$ одинаковыми значениями $D_{i,k+1}$ диапазона Δt_{k+1} . После такого «выравнивания» количество столбцов в матрице DM будет равно $J = \max(J_k | k=1, 2, \dots, K)$.

Наборы обучающих данных формируются из матрицы DM , при этом один набор X_j для момента времени t_j содержат значения котировок за промежуток времени $[t_{j-h}; t_j]$: $X_j = [DM_{j-h} \quad DM_{j-h+1}, \dots, DM_j]$, $j=h, h+1, \dots, J$, где h – историческая глубина анализируемых данных. Величина h может подбираться экспериментально, но для ее выбора рекомендуется рассчитывать время корреляции t_r для котировок с самым большим интервалом дискретизации $\Delta t_{max} = \max(\Delta T)$ из матрицы D и брать h с учетом условия $h \Delta t_{max} > t_r$.

Проведенный выше обзор показал, что для выявления аномалий в данных, представленных в форме временных рядов, широко применяется АЕ, что обусловлено особенностями их работы. Поэтому для выявления аномалий в имеющейся постановке задачи также предложена архитектура АЕ, в основе которой лежит рекуррентная нейронная сеть LSTM.

В приведенных выше обозначениях работу АЕ можно описать зависимостью $Y_j = f(g(X_j))$, где g – алгоритм кодировщика, отображающего X_j в скрытое состояние S , f – алгоритм декодера, разворачивающая S в выходные данные $Y_j \approx X_j$.

Архитектура разрабатывалась с применением инструмента Deep Network Designer среды MatLAB и представлена на рис. 1, где так же отражено, что соединение слоев выполнено корректно (об этом свидетельствует сообщение «errors 0»).

Параметры слоев на рис. 1 указаны для входных данных при $K=4$ и $N=2$, поэтому для других входных данных эти параметры нуждаются в адаптации, однако общая архитектура слоев остается неизменной. Для снижения вероятности переобучения в архитектуре используются слои прореживания (dropout).

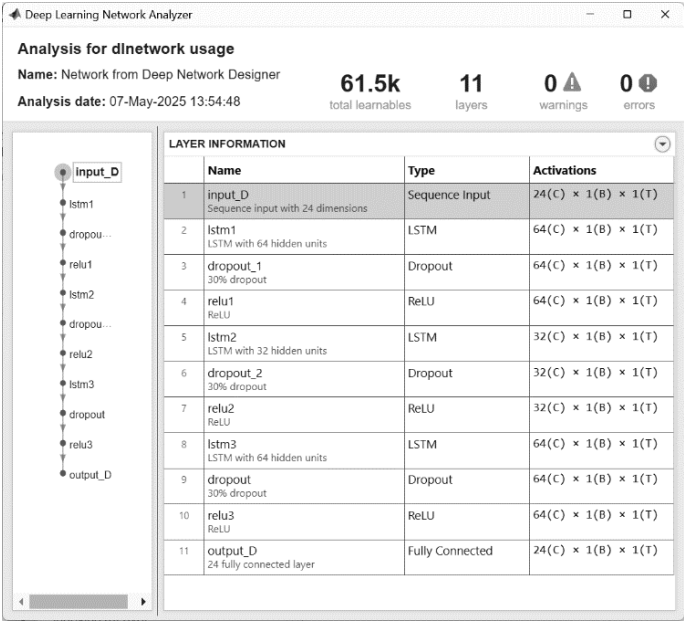


Рис. 1. Архитектура и параметры слоев АЕ

Количество входных признаков в первом слое (Sequence input) определялось исходя из формулы $3NK=32 \cdot 4=24$. Общее количество обучаемых параметров АЕ в данном случае составляет 61500, но очевидно, что при других K и N количество параметров будет меняться.

Учитывая сказанное, сам метод укрупненно можно представить в виде последовательности стандартных (для применения нейронных сетей) шагов: получение из входных данных матрицы (3.1); формирование обучающих наборов; адаптация архитектуры АЕ к форме входных данных; загрузка рабочих наборов данных и применение к ним АЕ; анализ результатов.

4. Результаты и обсуждение

Для апробирования предложенного метода были проведены модельные эксперименты с использованием реальных данных о курсах американского доллара и евро с 10 января 2025 по 1 мая 2025, представленные на сайте инвестиционной компании «ФИНАМ» (<https://www.finam.ru/>). Эти данные принимались за «нормальные». Данные были взяты из столбца «close» с дискретностью 30 минут, один час, 10 часов и один день – их фрагмент для курса евро (после выравнивания количества значений), представлен на рис. 2. Из них, в соответствии с (2.1), была сформирована матрица DM , а затем обучающие наборы X_j для АЕ. Стандартизация значений элементов X_j проводится автоматически в слое Sequence input с использованием метода $zscore(X_j)$. Всего было получено 3624 значений курса валют для $\Delta t_j = 30$ минут. Из этого количества 80% было взято для обучающего набора данных, а 20% – для валидационного.




Рис. 2. Фрагмент строк с номерами 1, 4, 7 и 10 матрицы DM

Обучение модели выполнялось на персональном компьютере с процессором Intel i5-12400 (2.50 GHz) и ОЗУ 16 Gb, время обучения составило 4 минуты 45 секунд. Использовался оптимизатор adam, метрики обучения RMSE и loss, количество эпох было принято относительно небольшим – 50, что рассматривалось как еще один инструмент (помимо слоев

dropout) для борьбы с переобучением. На последней эпохе обучения RMSE достигла значений 0.098 и 0.162 на обучающем и валидационном наборах, соответственно.

На сайте «ФИНАМ» отмечается, что «возможны сбои в поставке данных и отклонения, особенно в нерабочее время», но в эксперименте, для проверки детектирующей способности АЕ, в рабочий набор исходных данных с курсами валют за период с 2 по 30 декабря 2024 года аномалии были добавлены искусственно (на рис. 3 область с коллективной аномалией обведена овалом).




Рис. 3. Визуализация аномалии в данных

Внедренная аномалия трудно определяема статистическими методами, так как моменты различных порядков для «нормального» и «аномального» наборов будут практически одинаковыми. Применение АЕ, учитывающего «скорость» и «ускорение» изменение котировок, а также взаимосвязь с другими биржевыми инструментами (в данном случае курсом доллара) способно выявить подобную аномалию, так как в области аномалии RMSE имеет явное увеличение по сравнению с «нормальными» данными. Были проведены эксперименты с модификациями АЕ, которые обозначались цифрами: 1 – для $N = 2$, $K=4$ и с учетом первых и вторых разностей данных (далее – разностей); 2 – для $N = 2$, $K=4$, но без учета разностей; 3 – для $N = 2$, $K=1$ и с учетом разностей; 4 – для $N = 2$, $K=1$ и без учета разностей. Результаты эксперимента приведены на рис. 4, где RMSE для модификаций АЕ обозначены соответствующими подстрочными индексами.

На рис. 4 область значений j , которая соответствует аномалии в исходных данных, выделена прямоугольником. Визуальный анализ области позволяет сделать вывод, что применение АЕ на основе LSTM к многомасштабному признаковому пространству (значениям временного ряда, взятых с различными интервалами дискретизации) приводит к выраженному увеличению ошибки восстановления данных АЕ, что может быть использовано для классификации данных на аномальные и нормальные.




Рис. 4. RMSE на рабочем наборе данных

Для расчета метрики F1, характеризующей качество классификации данных на аномальные и нормальные, временная ось разбивалась на окна одинаковой длины. Если окно содержит аномальный паттерн (с увеличенной RMSE), все окно помечалось как аномальное. В результате, для представленных наборов данных и модификаций АЕ были получены следующие значения: для первой модификации $F1=0.84$, для второй $F1=0.79$, для третьей $F1=0.80$, для четвертой $F1=0.61$. Эти значения метрик уступают полученным в [A Multi-scale, 2024] и [Probabilistic, 2023a], где для различных наборов данных достигаются значения F1 от 0.80 и выше, однако подбор параметров N и K может сильно влиять на F1, что требует дальнейших исследований.

Заключение

В основе разработанного метода выявления аномалий в финансовых временных рядах, представленных с различной временной дискретизацией, лежит рекуррентная нейронная сеть LSTM, выполненная в архитектуре АЕ. Отличительной чертой метода выступает расширение признакового пространства АЕ за счет первых и вторых разностей многомасштабных исходных данных. Проведенные модельные эксперименты показали, что такое расширенное признаковое пространство позволяет добиться акцентированного увеличения ошибки восстановления входных данных при наличии коллективной аномалии в них.

Полученные результаты сейчас находят применение в учебном процессе по дисциплине «Интеллектуальные информационные системы» при освоении компетенций в области моделей машинного обучения. Также, полученные результаты могут быть использованы в алгоритмическом обеспечении систем автоматизации биржевой торговли.

Список литературы

- [**A Multi-scale, 2024**] Bao J., Gao H., Zhang C., Jia W., Gao J., Yang T. A Multi-scale Parallel Unsupervised Model for Multivariate Time Series Anomaly Detection // Artificial Intelligence Applications and Innovations. AIAI 2024. IFIP Advances in Information and Communication Technology. – 2024. – Vol 714. – doi.org/10.1007/978-3-031-63223-5_18.
- [**Azevedo, 2023**] Azevedo V., Hoegner C. Enhancing stock market anomalies with machine learning // Rev Quant Finan Acc. – 2023. – No. 60. – P. 195-230. – doi.org/10.1007/s11156-022-01099-z.
- [**Chahuan-Jimenez, 2024**] Chahuan-Jimenez K. Neural Network-Based Predictive Models for Stock Market Index Forecasting [Электронный ресурс] // J. Risk Financial Manag. – 2024. – No. 17(242). – URL: <https://doi.org/10.3390/jrfm17060242> (дата обращения: 25.04.2025).
- [**de Jesus, 2025**] de Jesus L.C., Fernandez-Navarro F., Carbonero-Ruz M. Enhancing financial time series forecasting through topological data analysis // Neural Comput & Applic. – 2025. – Vol. 37. – P. 6527-6545. – doi.org/10.1007/s00521-024-10787-x.
- [**Dorfeshan, 2022**] Dorfeshan Y., Taleizadeh A., Toloo M. Assessment of risk-sharing ratio with considering budget constraint and disruption risk under a triangular Pythagorean fuzzy environment in public-private partnership projects [Электронный ресурс] // Expert Systems with Applications. – 2022. – No. 203. – URL: <https://doi.org/10.1016/j.eswa.2022.117245> (дата обращения 20.04.2025).
- [**Gadimov, 2025**] Gadimov E., Birihanu E. Real-time suspicious detection framework for financial data streams // Int. j. inf. Technol. – 2025. – doi.org/10.1007/s41870-025-02529-6.
- [**Long, 2025a**] Tuhin K.H., Nobi A., Rakib M.H., Lee J.W. Long short-term memory autoencoder based network of financial indices // Humanit Soc Sci Commun. – 2025. – No. 12, 100. – doi.org/10.1057/s41599-025-04412-y.
- [**Mienye, 2025**] Mienye I.D., Swart T.G. Deep Autoencoder Neural Networks: A Comprehensive Review and New Perspectives // Arch Computat Methods Eng. – 2025. – doi.org/10.1007/s11831-025-10260-5.
- [**Pehlivan, 2024**] Pehlivan H. A novel outlier detection method based on Bayesian change point analysis and Hampel identifier for GNSS coordinate time series // EURASIP J. Adv. Signal Process. – 2024. – Vol. 2024, article number 44. – doi.org/10.1186/s13634-023-01097-w.
- [**Pricope, 2021**] Pricope T.-V. Deep Reinforcement Learning in Quantitative Algorithmic Trading: A Review [Электронный ресурс] // Computer Science. – 2021. – URL: [arXiv:2106.00123 \[cs.LG\]](https://arxiv.org/abs/2106.00123) (дата обращения 20.04.2025).
- [**Probabilistic, 2023a**] Zhang G., Gao X., Wang L., Xue B., Fu S., Yu J., Huang Z., Huang Xu. Probabilistic autoencoder with multi-scale feature extraction for multivariate time series anomaly detection // Appl Intell. – 2023. – Vol. 53. – P. 15855-15872. – doi.org/10.1007/s10489-022-04324-3.
- [**Sakib, 2025**] Sakib M. Ensemble deep learning techniques for time series analysis: a comprehensive review, applications, open issues, challenges, and future directions // Cluster Comput. – 2025. – No. 28(73). – doi.org/10.1007/s10586-024-04684-0.
- [**Sefati, 2025**] Sefati S.T., Razavi, S.N., Salehpour, P. Enhancing autoencoder models for multivariate time series anomaly detection: the role of noise and data amount // J Supercomput. – 2025. – 81, 559. – doi.org/10.1007/s11227-025-07044-w.

- [Time, 2023a] Jiang W., Zhang D., Ling L., Cai G., Zeng L. Time series to imaging-based deep learning model for detecting abnormal fluctuation in agriculture product price // Soft Comput. – 2023. – No. 27. – P. 14673-14688. – doi.org/10.1007/s00500-023-09121-9.
- [Verma, 2024] Verma A., Giri A.K., Debata B. ICT Diffusion, Financial Instability, and Shadow Economy: Panel Evidence from SAARC Economies [Электронный ресурс] // J Knowl Econ. – 2024. – URL: <https://doi.org/10.1007/s13132-024-02420-y>.
- [Зиненко, 2023] Зиненко А.В. Прогнозирование финансовых временных рядов с использованием сингулярного спектрального анализа // Бизнес-информатика. – 2023. – Т. 17, № 3. – С. 87-100. –DOI: 10.17323/2587-814X.2023.3.87.100.
- [Калмыков, 1986] Калмыков С.А., Шокин Ю.И., Юлдашев З.Х. Методы интервального анализа. – Новосибирск: Наука, 1986. – 222 с.
- [Прогнозирование, 2016a] Ярушев С.А., Федотова А.В., Тарасов В.Б., Аверкин А.Н. Прогнозирование временных рядов на основе гибридных нейронных сетей // Наука и образование: научное издание МГТУ им. Н.Э. Баумана. – 2016. – № 12. – С. 233-246. – doi: 10.7463/1216.0852597.
- [Стернин, 2005] Стернин М.Ю., Чугунов Н.В., Шепелев Г.И. Обобщенные интервальные оценки в моделях предметных областей систем поддержки экспертных решений // Труды Института системного анализа Российской академии наук. – 2005. – Т. 12. – С. 95-113.