

Выявление аномалий в экономических показателях на основе нейронной сети с глубинно-разделимыми свертками

В.С. Минин¹, Е.А. Кириллова^{2*}, Т.В. Какатунова², Е.В. Филимонова³

¹ООО «ВИСОМ», Смоленск, Россия

²Филиал Национального исследовательского университета «МЭИ» в г. Смоленске, Смоленск, Россия

³Университет «Синергия», Москва, Россия

*kirillova.el.al@yandex.ru

Аннотация. Выявление (детектирование) аномалий представляет собой актуальную исследовательскую задачу во многих предметных областях, решение которой позволяет своевременно принимать управленческие решения. В представляемом исследовании предложен метод выявления аномалий в экономических показателях, характеризующих внутреннюю и внешнюю среду производственной организации, который может быть применен в алгоритмическом обеспечении систем поддержки предпринимательского решения. В основе метода лежит использование искусственной нейронной сети с архитектурой автокодировщика и обученной повторять входные данные на выходе. После обучения автокодировщика на нормальных данных ошибка восстановления входа на выходе будет невелика, но при подаче аномальных данных ошибка будет возрастать, что может служить индикатором аномалии. В предложенном методе применяется сверточный автокодировщик, поэтому входные данные сначала преобразуются в изображения (сигнатуры), для чего предложен оригинальный способ их формирования. Способ заключается в представлении исторического поведения каждого экономического показателя в форме тепловой матрицы. Каждая тепловая матрица образует один канал, а их совокупность формирует сигнатуру, которая затем подается на вход автокодировщика для дальнейшего анализа. В автокодировщике использованы глубинно-разделимые свертки, что позволяет автономно настраивать сверточные фильтры по отдельным каналам сигнатур. Новизна результатов исследования состоит в разработанном методе выявления аномалий в массивах экономических показателей, позволяющем выполнять локализацию коллективных и единичных аномалий (выбросов), а также в разработанном программном обеспечении, с помощью которого проводилось апробирование метода. Выполненные вычислительные эксперименты показали, что метод достигает точности выявления аномалий, сопоставимой с некоторыми современными моделями.

Ключевые слова: анализ экономических показателей, детектирование аномалий в данных, глубокие искусственные нейронные сети, сверточный автокодировщик

Для цитирования: Минин В.С., Кириллова Е.А., Какатунова Т.В., Филимонова Е.В. Выявление аномалий в экономических показателях на основе нейронной сети с глубинно-разделимыми свертками // Прикладная информатика. 2025. Т. 20. № 6. С. 30–51. DOI: 10.37791/2687-0649-2025-20-6-30-51

© Минин В.С., Кириллова Е.А., Какатунова Т.В., Филимонова Е.В., 2025.

Anomaly detection in economic indicators based on a neural network with depthwise separable convolutions

V. Minin¹, E. Kirillova^{2*}, T. Kakatunova², E. Filimonova³

¹VISOM LLC, Smolensk, Russia

²Branch of the National Research University "MPEI" in Smolensk, Smolensk, Russia

³Synergy University, Moscow, Russia

*kirillova.el.al@yandex.ru

Abstract. Anomaly detection is a pressing research problem in many subject areas, the solution of which enables timely management decision-making. This study proposes a method for identifying anomalies in economic indicators characterizing the internal and external environment of a manufacturing organization. This method can be applied in the algorithmic support of business decision support systems. The method is based on the use of an artificial neural network with an autoencoder architecture trained to replicate input data at the output. After training the autoencoder on normal data, the error in reconstructing the input at the output will be small. However, when fed anomalous data, the error will increase, which can serve as an anomaly indicator. The proposed method uses a convolutional autoencoder, so the input data is first converted into images (signatures), for which an original method for their formation is proposed. The method involves representing the historical behavior of each economic indicator as a heat matrix. Each heat matrix forms one channel, and their combination forms a signature, which is then fed to the autoencoder input for further analysis. The autoencoder utilizes depthwise separable convolutions, allowing for autonomous tuning of convolutional filters for individual signature channels. The novelty of the research results lies in the developed method for detecting anomalies in economic indicator arrays, which enables localization of collective and individual anomalies (outliers), as well as in the developed software used to test the method. Computational experiments demonstrated that the method achieves anomaly detection accuracy comparable to some modern models.

Keywords: economic performance analysis, data anomaly detection, deep neural networks, convolutional autoencoder

For citation: Minin V., Kirillova E., Kakatunova T., Filimonova E. Anomaly detection in economic indicators based on a neural network with depthwise separable convolutions. *Prikladnaya informatika*=Journal of Applied Informatics, 2025, vol.20, no.6, pp.30-51 (in Russian). DOI: 10.37791/2687-0649-2025-20-6-30-51

© Minin V., Kirillova E., Kakatunova T., Filimonova E., 2025.

Введение

Результат интеграции экономической деятельности в регулируемую цифровую структуру международной экономики можно характеризовать как киберфизическую интегрированную экономику, для которой характерно значительное возрастание объемов ин-

формации, обработка которой позволяет заблаговременно выявлять негативные тенденции в экономической среде и получать за счет этого конкурентные преимущества. К сожалению, сейчас наблюдается рост аномалий в данных в контексте экономической деятельности, что создает серьезные угрозы обоснованно-

сти принятия управленческих решений [1], которые играют важную роль в обеспечении эффективности деятельности производственных организаций и гарантируют их устойчивое развитие и расширение бизнес-интересов в различных направлениях.

Предпринимательское решение, как один из вариантов управленческих решений, направлено на обоснование того или иного комплекса мероприятий (организационных, технологических, социально-экономических), осуществляемых руководящими сотрудниками в рамках их компетенций и полномочий с целью достижения бизнес-целей организации. Общая схема формирования предпринимательских решений может быть представлена в виде схемы, показанной на рисунке 1, на котором возможные альтернативные направления развития организации обозначены «Проект 1», «Проект 2», ..., «Проект N_{Π} », где N_{Π} – общее количество альтернативных проектов.

Бизнес-цели организации выступают как методологическая основа для сравнения альтернатив в процессе принятия предпринимательского решения на ос-

нове анализа экономических показателей внешней и внутренней среды организации.

В ряде случаев проекты-альтернативы направлены на совершенствование производственных процессов, номенклатуры изделий и услуг, цепочек поставок и сбыта, а также других аспектов деятельности предприятия. При этом цена ошибки при выборе неудачной альтернативы возрастает по мере повышения уровня принятия решений в иерархии управления производством. В этой связи актуальной исследовательской задачей выступает разработка методов выявления нестандартных ситуации во внешней и внутренней среде организации [2].

Под нестандартной ситуацией здесь понимается сложившаяся совокупность экономических показателей, описывающих внешнюю и внутреннюю среду производственной организации, которая ранее не встречалась в исторической ретроспективе (аномалия данных) и которая влияет на функционирование организации, причем это влияние может быть как отрицательным, так и положительным, открывающим новые возможности для наращивания

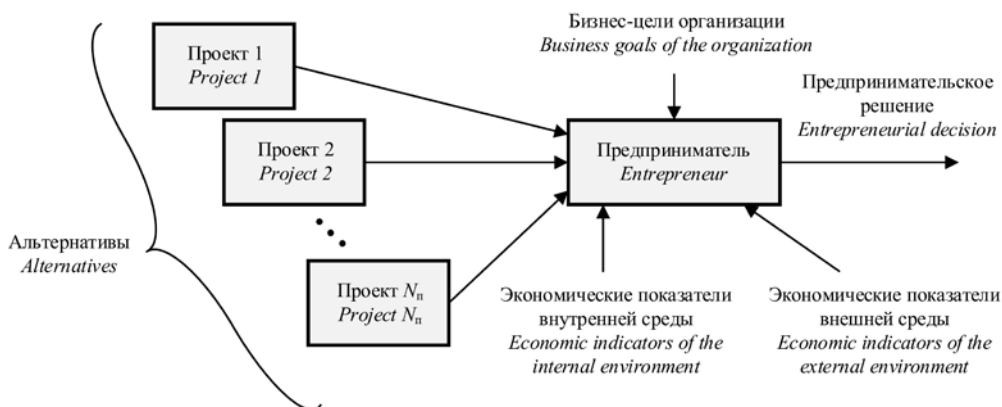


Рис. 1. Схема формирования предпринимательского решения

Fig. 1. Scheme of formation of an entrepreneurial decision

производства и расширения бизнеса. При этом выявленные аномалии могут использоваться для предсказания мошеннических действий, выходов из строя оборудования, возникновения аварийных ситуаций, выявления аномального спроса и других существенных событий.

При оценке состояния организации совокупность включаемых в рассмотрение бизнес-процессов определяется уровнем управления, для которого проводится оценка, а состав применяемых экономических показателей отражает степень влияния принимаемых решений. Всё это приводит к трудностям при толковании текущего состояния без дополнительного анализа экономических показателей. Поэтому на первом этапе определения нестандартных ситуаций целесообразно выявлять ранее не встречавшиеся комбинации значений показателей, что трактуется как выявление аномалий в имеющихся данных, способное привлечь внимание руководства. Даже грубый анализ экономических показателей, характеризуемых как аномальные, дает возможность руководству своевременно принимать упреждающие меры, позволяющие воспользоваться такой ситуацией или минимизировать издержки от ее воздействия на организацию, обеспечивать конкурентную политику в системе стратегического планирования [3].

Цель исследования состояла в создании метода и модели выявления аномалий в многомерных данных, содержащих экономические показатели внешней и внутренней среды производственной организации, обеспечивающих точность, сопоставимую с современными нейросетевыми моделями, но с более простой архитектурой.

Новизна результатов исследования состоит в предложенном методе выявления аномалий, использующем искусственную нейронную сеть в архитектуре автокодировщика (автоэнкодер, Autoencoder, AE), с глубинно-разделимыми свертками, а также в результатах модельного эксперимента, проведенного с разработанным программным инструментом, реализующим предложенный метод.

Современные подходы к выявлению аномалий в экономических показателях

Для обнаружения аномалий (Anomaly Detection, AD) применяются различные индикаторы и методы. Часть методов включают кластерный коэффициент, энтропию, анализ тензора корреляции, обнаружение петлевой причинности, анализ персистентной гомологии, комплексный индикатор с использованием машины Больцмана [1]. В [4] делается вывод о больших потенциальных возможностях искусственного интеллекта в задаче AD и снижения неопределенности предпринимательских стратегий, особенно с учетом использования гибридных фреймворков.

Задача AD не имеет универсального решения, так как сами аномалии могут трактоваться по-разному в зависимости от предметной области, целей обнаружения и в наиболее общем случае можно указать следующие их разновидности: выявление «новизны» в данных (Novelty Detection) и детектирование выбросов (Outlier Detection) [5, 6]. Рассматривая всю совокупность методов и подходов к выявлению аномалий в данных, можно указать следующий их набор: статистические методы; метрические методы, такие

как k ближайших соседей, обнаружение выбросов на основе угла (Angle-Based Outlier Detection, ABOD), локальный фактор выброса (Local Outlier Factor, LOF); метод опорных векторов (Support Vector Machine, SVM) с одним классом (One-Class SVM), изолирующий лес (Isolate Forest) [7], методы на основе эллиптической огибающей (Elliptic Envelope) [8], кластерные методы, метод главных компонент, алгоритмы на основе прогнозирования временных рядов, обучение с учителем (регрессия, классификация), модельные тесты.

Одним из новых подходов к выявлению аномалий сейчас можно считать применение графовых нейронных сетей (Graph Neural Network, GNN), адаптированных для работы с данными, структурированными в виде графов.

В [9] предложена модель в виде комбинации слоев GNN в архитектуре вариационного автокодировщика. Благодаря архитектуре автокодировщика предложенная в [9] модель менее склонна к переобучению и превзошла существующие модели на четырех из пяти реальных наборов данных с органическими.

В ряде предметных областей смысл термина «аномалия данных» может быть строго не определен, например при выявлении аномальных кластеров в динамической торговой сети [10].

Исследованию аномалий фондового рынка, существенно влияющих на доходность акций, посвящена работа [11], где отмечается их заметное влияние на экономические показатели.

Метод анализа перекрестных аномалий как одного из видов аномалий в данных, характеризуемого совместным влиянием нескольких контролируемых факторов

на принятие решения о наличии аномалии, представлен в [12]. Авторы констатируют важность выявления аномалий для улучшения возможностей традиционных ценовых моделей.

В [13] обнаружение аномалий применяется в анализе доходности криптовалют, в [14] – для обнаружения недостоверных сведений о потребляемой электроэнергии.

При анализе современного состояния исследований в области выявления аномалий в данных, связанных с экономической деятельностью, был рассмотрен еще ряд работ, в частности [15–17]. Можно отметить, что при детектировании аномалий в данных широко применяются такие мощные нейросетевые инструменты, как автокодировщики и генеративные состязательные сети (Generative Adversarial Network, GAN). В GAN есть две части – генератор и дискриминатор, позволяющие обнаружить семплы, однако хорошо натренировать пару «генератор – дискриминатор» на практике непросто, что ограничивает области применения таких моделей.

Востребованность детектирования аномалий в различных прикладных областях привела к появлению широкого спектра средств автоматизированного выявления аномалий. Например, в состав языка R входит пакет `anomalize()` для обнаружения аномалий в многомерных временных рядах. Однако его применение требует навыков программирования, кроме того, сам метод использует статистические модели, что не позволяет выявлять глубинные аномалии. В MatLab присутствует объект `deepSignalAnomalyDetector`, создающий объект детектора аномалий сигнала на основе одномерного сверточного автоэнкодера, но MatLab является пропри-

старным программным обеспечением, что значительно сужает область его применения. Еще одним представителем специализированного программного обеспечения выступает библиотека PyOD, включающая широкий класс алгоритмов обнаружения аномалий на языке Python, перечень программ которой начинается с классических, таких как Isolation Forest, и заканчивается новейшими методами глубокого обучения и такими алгоритмами, как COPOD (Copula-Based Outlier Detection), который применяется для обнаружения выбросов [18].

Проведенный анализ работ показывает, что наиболее перспективным направлением достижения поставленной цели исследования может быть применение нейронных сетей, например, в архитектуре автокодировщика для АД в экономических показателях, что и будет сделано далее.

Постановка задачи АД в экономических показателях

Предполагается, что имеется набор экономических показателей производственной организации, не имеющих аномалий (нормальные данные) и представленных в форме временных рядов, сгруппированных по строкам в массивы \mathbf{Q}_{normal} и \mathbf{D}_{normal} . Массив \mathbf{Q}_{normal} отражает показатели внешней среды по отношению к организации, а \mathbf{D}_{normal} – внутренней. Так как поступление данных о различных показателях чаще всего не синхронизировано между собой, то и моменты времени для каждого из показателей в массивах \mathbf{Q}_{normal} и \mathbf{D}_{normal} могут быть разными. Это же обстоятельство приводит к тому, что количество элементов в строках может быть различно:

$$\mathbf{Q}_{normal} = \left(\begin{array}{c} q_1(t_i - k_1\Delta t_1), q_1(t_i - (k_1 - 1)\Delta t_1), \dots, q_1(t_i - \Delta t_1), q_1(t_i) \\ q_2(t_i - k_2\Delta t_2), q_2(t_i - (k_2 - 1)\Delta t_2), \dots, q_2(t_i - \Delta t_2), q_2(t_i) \\ \dots \\ q_{s-1}(t_i - k_{s-1}\Delta t_{s-1}), q_{s-1}(t_i - (k_{s-1} - 1)\Delta t_{s-1}), \dots, q_{s-1}(t_i - \Delta t_{s-1}), q_{s-1}(t_i) \\ q_s(t_i - k_s\Delta t_s), q_s(t_i - (k_s - 1)\Delta t_s), \dots, q_s(t_i - \Delta t_s), q_s(t_i) \end{array} \right), \quad (1)$$

$$\mathbf{D}_{normal} = \left(\begin{array}{c} d_1(t_i - k_{1+s}\Delta t_{s+1}), d_1(t_i - (k_{1+s} - 1)\Delta t_{s+1}), \dots, d_1(t_i - \Delta t_{s+1}), d_1(t_i) \\ d_2(t_i - k_{2+s}\Delta t_{s+2}), d_2(t_i - (k_{2+s} - 1)\Delta t_{s+2}), \dots, d_2(t_i - \Delta t_{s+2}), d_2(t_i) \\ \dots \\ d_{w-1}(t_i - k_{w+s-1}\Delta t_{w+s-1}), d_{w-1}(t_i - (k_{w+s-1} - 1)\Delta t_{w+s-1}), \dots, d_{w-1}(t_i - \Delta t_{w+s-1}), d_{w-1}(t_i) \\ d_w(t_i - k_{w+s}\Delta t_{w+s}), d_w(t_i - (k_{w+s} - 1)\Delta t_{w+s}), \dots, d_w(t_i - \Delta t_{w+s}), d_w(t_i) \end{array} \right), \quad (2)$$

где s, w – количество контролируемых экономических показателей внешней и внутренней среды организации соответственно;

$\Delta t_1, \Delta t_2, \dots, \Delta t_{w+s}$ – интервалы дискретизации, с которой информация об различных экономических показателях поступает в хранилище данных организации;

k_1, k_2, \dots, k_{w+s} – количество значений (отчетов) различных экономических показателей $q_1, q_2, \dots, q_s, d_1, d_2, \dots, d_w$ соответственно (общее их количество равно $w+s$).

Интервалы дискретизации могут быть непостоянными, в результате данные о соответствующих показателях в строках массивов $\mathbf{Q}_{\text{normal}}$ и $\mathbf{D}_{\text{normal}}$ будут представлять собой нерегулярные временные ряды. Непостоянство интервалов дискретизации может быть отражено как функция от непрерывного времени, а совокупность интервалов представлена в виде вектора

$$\Delta \mathbf{T}(t) = [\Delta t_1(t), \Delta t_2(t), \dots, \Delta t_s(t), \Delta t_{s+1}(t), \Delta t_{s+2}(t), \dots, \Delta t_{w+s}(t)].$$

Имеются рабочие наборы экономических показателей производственной организации \mathbf{Q}_{work} и \mathbf{D}_{work} , в которых необходимо определить наличие аномалий или их отсутствие. Общая структура массивов \mathbf{Q}_{work} и \mathbf{D}_{work} совпадает с (1) и (2) соответственно, но количество элементов в строках может быть другим, и данные в строках могут содержать аномалии.

Ставится задача выявления и локализации коллективных и единичных аномалий (выбросов) в массивах \mathbf{Q}_{work} и \mathbf{D}_{work} на основе известных $\mathbf{Q}_{\text{normal}}$ и $\mathbf{D}_{\text{normal}}$, где под локализацией понимается указание временного интервала аномальной группы значений и номера экономического показателя, где наблюдается аномалия.

Метод выявления аномалий

Проведенный обзор существующих методов и подходов к выявлению различных видов аномалий в данных для экономических приложений позволяет сделать выбор основной концепции «решателя» в методе АД в пользу архитектуры «автокодировщик», использующей обучение без учителя. Основной смысл функционирования АЕ заключается в воспроизведении входных данных на выходе с минимальной ошибкой, поэтому он обучается на «нормальных» данных. При подаче на вход аномальных данных, то есть тех, которых не было в обучающей выборке, АЕ на выходе выдает данные, сильно отличающиеся от входных, то есть с большой ошибкой. Именно величина ошибки может служить индикатором наличия аномалий. Обобщенная структура АЕ для изображений показана на рисунке 2.

На рисунке 2 введены обозначения: $\{\mathbf{Q}, \mathbf{D}\}$ – наборы входных данных в форме (1) и (2); $F()$ – функция кодера, на выходе которого формируется сжатое (внутреннее) представление входных данных; $G()$ – функция декодера, восстанавливающая входные данные из сжатого представления; $R()$ – функция преобразования всего АЕ.

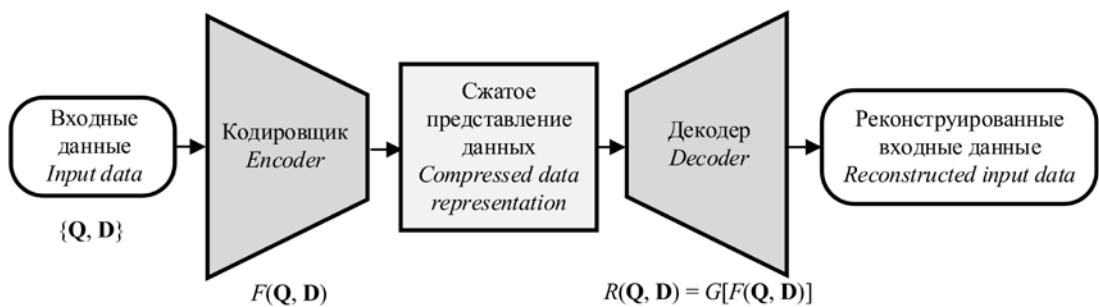


Рис. 2. Структура АЕ

Fig. 2. AE structure

Обучение АЕ без учителя предполагает, что, обучаясь на «нормальных» данных вида (1) и (2), АЕ пытается минимизировать ошибку воспроизведения на выходе каждой версии исходной выборки: $eps = \|R(\mathbf{Q}, \mathbf{D}) - \{\mathbf{Q}, \mathbf{D}\}\|$, где двойные вертикальные скобки обозначают норму – численную меру расстояния между элементами разности, выбираемую на этапе подготовки АЕ к обучению.

Формирование скрытого состояния $F(\mathbf{Q}, \mathbf{D})$ позволяет АЕ выявлять наиболее значимые признаки во входных данных для их восстановления, показывая лучшие результаты при детектировании аномалий, чем метод главных компонент [19].

После выбора концепции построения «решателя» для метода АД в экономических показателях была проведена детализация архитектуры слоев АЕ, так как от этого во многом зависит точность выявления аномалий. Предложено использовать в основе архитектуры АЕ слои с отдельной сверткой по глубине (Depthwise Separable Convolutions, DSC) [20]. Соответственно, применяемый в методе выявления аномалий автокодировщик далее обозначен как DSC-AE; так же будет обозначаться и модель, реализующая метод. Отличительной чертой этой свертки выступает то, что она предполагает полную независимость разных каналов, в то время как при обработке изображений формата RGB каналные изображения сильно коррелированы. Подбор фильтров свертки для каждого канала входных данных в отдельности при обучении сети позволяет выделять уникальные признаки в данных каждого канала. Это способствует более эффективному использованию обучающих данных по сравнению с обычной двумерной

сверткой, что проявляется в более быстрой сходимости обучения и меньшем объеме требуемых данных [21]. В высокоуровневом API Keras для создания моделей глубокого обучения на языке Python глубинно-разделимую свертку реализует слой SeparableConv2D, а в MatLab – слой groupedConvolution2dLayer.

Двумерные свертки работают с изображениями, а (1) и (2) представляют собой наборы временных рядов, то есть числовые данные. Поэтому было предложено сначала сформировать псевдоизображения (сигнатуры) из данных о каждом экономическом показателе – эта операция проводится в несколько этапов. В (1) и (2) количество элементов в строках может быть разным, а интервалы дискретизации нерегулярными, поэтому вначале выполняется передискретизация исходных данных в соответствии с алгоритмом, псевдокод которого представлен в листинге 1.

Листинг 1. Алгоритм вторичной дискретизации входных данных

Listing 1. Input data resampling algorithm

```

function [QR, Δtmin]=Resample(Q, ΔT)
1. s = length(Q(:,1))
2. jmax = max(length(rows(Q)))
3. Δtmin = min(ΔT)
4. for i = 1, ..., s do
5.     k = 1
6.     for j = 1, ..., jmax do
7.         if jΔtmin < kΔti
8.             QR(i,j) = (Q(i, k)
9.         else
10.            k = k+1
11.            QR(i,j) = (Q(i, k)
12.         end if
13.     end for
14. end for
end function
    
```

В результате применения функции Resample из листинга 1 к массивам $\mathbf{Q}_{\text{normal}}$ и $\mathbf{D}_{\text{normal}}$ получаются массивы $\mathbf{Q}_{\text{RQ}} = \text{Resample}(\mathbf{Q}_{\text{normal}}, \Delta T)$ и $\mathbf{D}_{\text{RD}} = \text{Resample}(\mathbf{D}_{\text{normal}}, \Delta T)$, в каждом из которых строки одинаковой длины.

Массивы \mathbf{Q}_{RQ} и \mathbf{D}_{RD} служат источником обучающих данных – из них формируются входные данные для DSC-AE в форме сигнатур. Для этого задается количество отсчетов исторической глубины данных h , а в абсолютном выражении историческая ретроспектива составит $h\Delta t_{\text{min}}$. Величина h задает размер окна данных (длительность фрагмента наблюдений), в котором выявляются аномалии, и определяет, сколько значений показателей будет учитываться, начиная от текущего момента времени t_i .

Формировать наборы данных из \mathbf{Q}_{RQ} при заданном h можно по-разному, например блоками, в которых присутствуют все показатели от текущего момента времени t_i до $(t_i - h\Delta t_{\text{min}})$ [22, 23]. Однако такой подход неудобен при относительно небольшом количестве параметров, так как приводит к малому размеру формируемых сигнатур, что создает трудности их классификации.

В представляемом методе для формирования одного набора обучающих данных используется только один показатель: в первой строке набора будут значения, начиная от момента t_i , а в нижеследующих – значения, сдвинутые на 1. Всего строк в одном наборе будет $h+1$, что позволит формировать матрицы размером $(h+1) \times (h+1)$. Такой подход приводит к тому, что фактически историческая глубина анализируемых данных будет составлять $2h$, что нужно учитывать при формировании обучающих наборов данных. Выбор величины h позволяет получать сигнатуры достаточно большого размера для анализа нейронными сетями, не ограниченные количеством контролируемых экономических показателей, что отмечалось выше. В результате такой компоновки входные обучающие данные будут представлять собой совокупность тензоров $\{\mathbf{X}_{\text{Q}(i-h)}; \mathbf{X}_{\text{Q}(i-h+1)}; \dots, \mathbf{X}_{\text{Q}i}\}$. Например, для i -го момента времени, то есть для тензора $\mathbf{X}_{\text{Q}i}$, его первая страница (для первого показателя), матрица $\mathbf{X}_{\text{Q}1,i}$, будет иметь вид

$$\mathbf{X}_{\text{Q}1,i} = \begin{pmatrix} q_{\text{RQ}1}(t_i - h\Delta t_{\text{min}}), q_{\text{RQ}1}(t_i - (h-1)\Delta t_{\text{min}}), \dots, q_{\text{RQ}1}(t_i - \Delta t_{\text{min}}), q_{\text{RQ}1}(t_i) \\ q_{\text{RQ}1}(t_{i-1} - h\Delta t_{\text{min}}), q_{\text{RQ}1}(t_{i-1} - (h-1)\Delta t_{\text{min}}), \dots, q_{\text{RQ}1}(t_{i-1} - \Delta t_{\text{min}}), q_{\text{RQ}1}(t_{i-1}) \\ \vdots \\ q_{\text{RQ}1}(t_{i-h+1} - h\Delta t_{\text{min}}), \dots, q_{\text{RQ}1}(t_{i-h+1} - \Delta t_{\text{min}}), q_{\text{RQ}1}(t_{i-h+1}) \end{pmatrix}. \quad (3)$$

Аналогично формируются обучающие наборы данных $\mathbf{X}_{\text{D}i}$ для матрицы \mathbf{D}_{RD} . Отметим, что так как проводилась вторичная дискретизация, то количество элементов в строках \mathbf{Q}_{RQ} и \mathbf{D}_{RD} будет одинаковым, а соответственно, и количество матриц в обучающих наборах тоже. Количество же строк в них остается прежним: в \mathbf{Q}_{RQ} их s , а в \mathbf{D}_{RD} – w .

Для каждого $\mathbf{X}_{\text{Q}i}$ и $\mathbf{X}_{\text{D}i}$ формируется тепловая матрица (здесь двоеточие означает, что берутся все элементы первой размерности, то есть все показатели для i -го момента времени), а их совокупность создает сигнатуру одного примера для DSC-AE. Структура одной сигнатуры проиллюстрирована на рисунке 3.

Сигнатура одного элемента обучающего набора данных
Signature of one element of the training dataset




Рис. 3. Структура сигнатуры данных

Fig. 3. Data signature structure

После обучения DSC-AE на данных, получаемых после вторичной дискретизации $\mathbf{Q}_{\text{normal}}$ и $\mathbf{D}_{\text{normal}}$, он применяется на рабочем наборе \mathbf{Q}_{work} и \mathbf{D}_{work} , в результате чего формируются восстановленные сигнатуры $R(\mathbf{Q}_{\text{work}}, \mathbf{D}_{\text{work}})$, анализ которых позволяет сделать вывод о наличии или об отсутствии аномалий во входных данных \mathbf{Q}_{work} и \mathbf{D}_{work} . При ее наличии сигнатуры подвергаются дальнейшему анализу с целью локализации аномалии. Структура взаимодействия отдельных операций обработки данных в представляемом методе выявления аномалий в экономических показателях показана на рисунке 4.

В начале проведения операций обработки данных по методу AD проводится их нормализация, заключающаяся в приведении значений в (1) и (2) к диапазону 0–255, а также к типу данных uint8 (беззнаковое целое), чтобы формат соответ-

ствовал применяемому в изображениях и на который рассчитаны сверточные нейронные сети.

Расчет ошибки восстановления сигнатуры выполняется по каждому слою тензора сигнатуры с последующим усреднением:

$$e_{k,i} = \sqrt{\frac{\sum_{n=1}^{h+1} \sum_{m=1}^{h+1} [(r_{k,i})_{n,m} - (q_{RQ_{k,i}})_{n,m}]^2}{(h+1)^2}}, \quad (4)$$

где $e_{k,i}$ – среднеквадратичная ошибка (Root Mean Squared Error, RMSE) для k -го экономического показателя в i -й момент времени;

$r_{k,i}$ – значение пикселя в восстановленной сигнатуре k -го показателя в i -й момент времени;

$q_{RQ_{k,i}}$ – значение элемента из \mathbf{X}_{Q_i} (для \mathbf{X}_{D_i} для данных из \mathbf{D}).

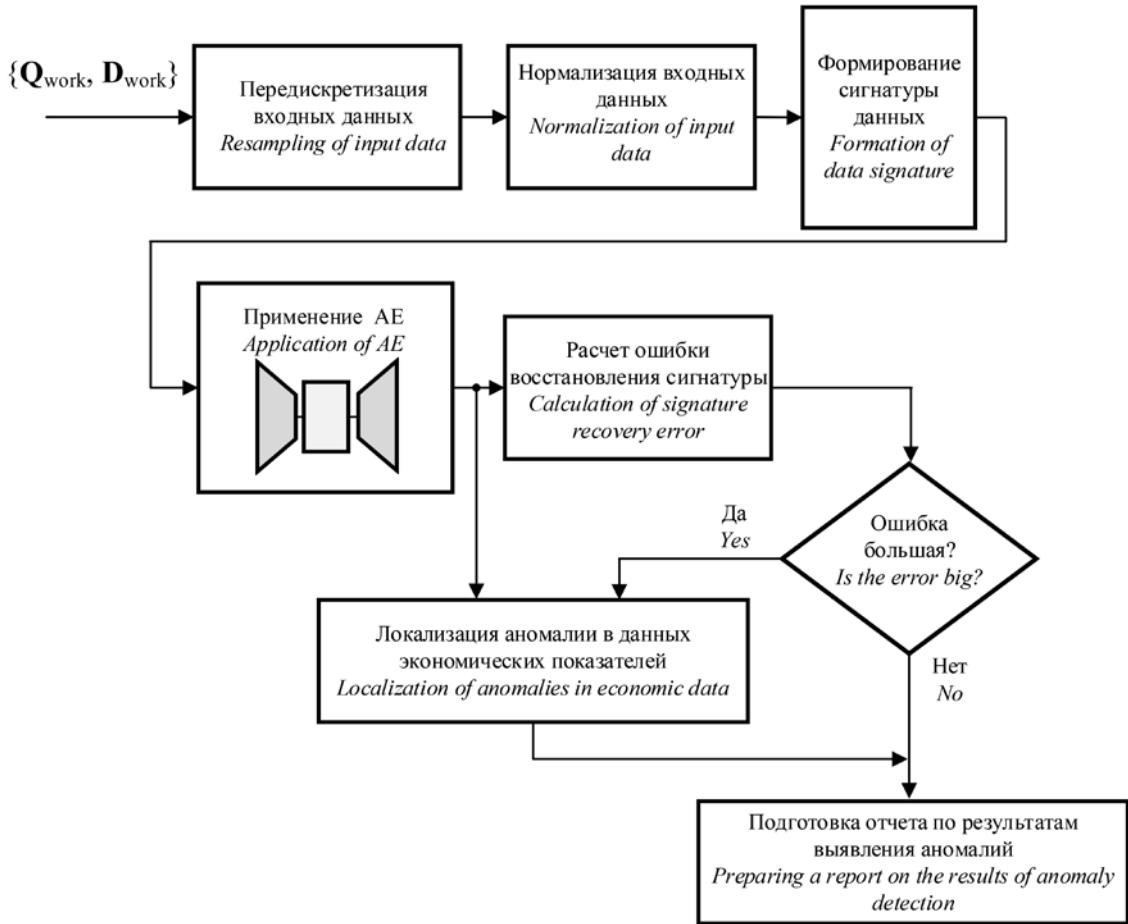


Рис. 4. Взаимодействие операций обработки данных метода AD

Fig. 4. Interaction of AD method data processing operations

После вычисления ошибок для каждого канала в i -й момент времени вычисляется усредненная ошибка для всех каналов:

$$e_i = \frac{\sum_{k=1}^{s+w} e_{k,i}}{s + w}. \quad (5)$$

Величина e_i сравнивается с ошибкой e_{AE} , полученной в процессе обучения DSC-AE, и если она превышает ее, делается вывод о наличии аномалий в данных, и аномалия локализуется. Для этого выявляются номера каналов k и момен-

тов времени i , для которых $e_{k,i}$ превышает e_{AE} – тем самым проводится процедура пространственной (по номеру канала) и временной (по номеру момента времени i) локализации аномалий.

При разработке архитектуры DSC-AE был учтен тот факт, что применение слоя макспулинга (MaxPooling2D) для уменьшения разрешения карт признаков уничтожает информацию о местоположении признака, так как просто выбирает максимальное значение в заданном окне. В случае с сигнатурами такая привязка важна, так как позволяет сопоставлять различ-

ные временные промежутки с учетом динамики анализируемых показателей. Поэтому было предложено использовать свертку с увеличенным шагом ($strides=2$), которая, уменьшая разрешения карт признаков, сохраняет информацию о местоположении признака.

На рисунке 5 представлен список слоев последовательной архитектуры DSC-AE (для $h = 103, s = 3, w = 3$). Слои с номерами с 1 по 10 представляют кодер. Слои с номерами 2, 5 и 8 реализуют раздельную свертку по глубине, у которых параметр NumGroups (количество каналов в группе) установлен в значение

channel-wise (по каналам). Оставшиеся слои реализуют декодер. Кодер представляет собой стек слоев Conv2DTranspose, выполняющих преобразования, которые увеличивают разрешение карт признаков до размеров исходных изображений (сигнатур): на выходе они имеют формат 104×104 пикселя в шести каналах соответственно e формату выхода.

Представленная архитектура AE содержит 1,7 миллиона настраиваемых в процессе обучения параметров, в ней для снижения риска переобучения содержатся слои прореживания (Dropout), что снижает требования к объему обучающих

LAYER INFORMATION				
	Name	Type	Activations	Number of Learnables
1	imageinput	Image Input	$104(S) \times 104(S) \times 6(C) \times 1(B)$	0
2	groupedconv	2-D Grouped Convolution	$104(S) \times 104(S) \times 36(C) \times 1(B)$	360
3	batchnorm	Batch Normalization	$104(S) \times 104(S) \times 36(C) \times 1(B)$	72
4	relu	ReLU	$104(S) \times 104(S) \times 36(C) \times 1(B)$	0
5	dropout	Dropout	$104(S) \times 104(S) \times 36(C) \times 1(B)$	0
6	groupedconv_1	2-D Grouped Convolution	$52(S) \times 52(S) \times 432(C) \times 1(B)$	4320
7	batchnorm_1	Batch Normalization	$52(S) \times 52(S) \times 432(C) \times 1(B)$	864
8	relu_1	ReLU	$52(S) \times 52(S) \times 432(C) \times 1(B)$	0
9	dropout_1	Dropout	$52(S) \times 52(S) \times 432(C) \times 1(B)$	0
10	groupedconv_2	2-D Grouped Convolution	$26(S) \times 26(S) \times 20736(C) \times 1(B)$	207360
11	batchnorm_2	Batch Normalization	$26(S) \times 26(S) \times 20736(C) \times 1(B)$	41472
12	relu_2	ReLU	$26(S) \times 26(S) \times 20736(C) \times 1(B)$	0
13	dropout_2	Dropout	$26(S) \times 26(S) \times 20736(C) \times 1(B)$	0
14	transposed-conv	2-D Transposed Convolution	$52(S) \times 52(S) \times 8(C) \times 1(B)$	1493000
15	batchnorm_3	Batch Normalization	$52(S) \times 52(S) \times 8(C) \times 1(B)$	16
16	relu_3	ReLU	$52(S) \times 52(S) \times 8(C) \times 1(B)$	0
17	dropout_3	Dropout	$52(S) \times 52(S) \times 8(C) \times 1(B)$	0
18	transposed-conv_1	2-D Transposed Convolution	$104(S) \times 104(S) \times 8(C) \times 1(B)$	584
19	batchnorm_4	Batch Normalization	$104(S) \times 104(S) \times 8(C) \times 1(B)$	16
20	relu_4	ReLU	$104(S) \times 104(S) \times 8(C) \times 1(B)$	0
21	dropout_4	Dropout	$104(S) \times 104(S) \times 8(C) \times 1(B)$	0
22	transposed-conv_2	2-D Transposed Convolution	$104(S) \times 104(S) \times 6(C) \times 1(B)$	438

Рис. 5. Результаты анализа корректности архитектуры DSC-AE

Fig. 5. Results of the DSC-AE architecture correctness analysis

данных и бывает актуально при относительно небольших выборках экономических показателей.

Расчет ошибки восстановления сигнатур реализуют функции, псевдокод которых представлен в листинге 2. Функция ChannelError принимает исходную и восстановленную сигнатуры (в обозначениях функции это X_i и Y_i соответственно) для i -го момента времени, а возвращает ошибки восстановления с разбиением по каналам для текущего момента времени: тензор EM формой $(h+1) \times (h+1) \times k$ со-

держит ошибки восстановления входных сигнатур по каждому пикселю, а вектор $Ev_channel$ – среднеквадратичные ошибки восстановления по каждому каналу. Большие величины ошибок в $Ev_channel$ будут свидетельствовать о наличии аномалии в этом канале (локализация канала), а изображение тепловой матрицы EM для этого канала позволит обнаружить интервалы времени возникновения аномалий как более яркие области, характеризующие большее значение ошибки.

Листинг 2. Алгоритмы расчета ошибки восстановления

Listing 2. Algorithms for calculating recovery error

```

function [EM, Ev_channel]= ChannelError (Xi, Yi)
    1. [h, h, K] = size(Yi)
    2. sum = 0
    3. k = 1
    4. E_channel = [], EM = []
    5. while k<K
    6.     EM(:, :, k) = (Yi(:, :, k) - Xi(:, :, k))^2
    7.     for n = 1, ..., h do
    8.         for m = 1, ..., h do
    9.             sum=sum+ (Yi(n,m,k) - Xi(n,m,k))^2
    10.        end for
    11.    end for
    12.    Ev_channel[k] = (sum/(n^2))^1/2
    13.    k=k+1
    14. end while
end function

function [e_sum, EM_time, Ev_time]= TemporaryError (X, Y)
    1. [h, h, K, T] = size(Y)
    2. i = 1
    3. Ev_time = [], EM_time = []
    4. while i<T
    5.     [EM_time(i), Ev_time(i)]= ChannelError(X(i), Y (i))
    6.     i=i+1
    7. end while
    8. e_sum = sum(Ev_time)/T
end function

```

Функция `TemporaryError` принимает исходную и восстановленную сигнатуры (в обозначениях функции это X и Y соответственно) за весь временной интервал анализа рабочих данных. Функция вызывает в своем теле функцию `ChannelError` и возвращает `e_sum` – величину усредненной ошибки по всем каналам и всему времени наблюдения (ее величина служит индикатором наличия аномалии в рассматриваемом временном интервале, который анализируется DSC-AE). **EM_time** – четырехмерный тензор, интерпретируемый как последовательность трехмерных тензоров, каждый из которых содержит каналные тепловые матрицы для i -го момента времени. **Ev_time** – тензор, содержащий последовательность векторов среднеквадратичных ошибок вос-

становления для каждого канала для i -го момента времени.

С учетом введенных функций псевдокод алгоритма, который реализует предлагаемый метод AD и оформлен в виде функции AD, представлен в листинге 3.

На вход функции AD подаются рабочие наборы данных Q_{work} и D_{work} , вектор интервалов дискретизации ΔT , историческая глубина h и ошибка eps , достигнутая в процессе обучения DSC-AE. Результатом работы функции выступают матрица **kv**, в столбцах которой содержатся номера каналов, где величина ошибки превышает eps , количество столбцов в **kv** равно количеству образцов, поступающих на вход AE, и матрица **iT**, представляющая собой вектор-строку, содержащую моменты времени, когда зафиксированы аномалии.

Листинг 3. Алгоритм выявления аномалий

Listing 3. Anomaly detection algorithm

```

function [kv, iT]= AD (Qwork, Dwork, ΔT, h, eps)
    1. XD = [Qwork; Dwork]
    2. XD = Normalize(XD)
    3. [XD, Δtmin] = Resample(XD, ΔT)
    4. [K, T]=size(XD)
    5. X = [XD(1: h), ..., XD(T - h - 1: T - 1)], XD(T - h: T)]
    6. X= uint8(normalize (X, [0,255]))
    7. Y = AE(X)
    8. [esum, EM_time, Ev_time]= TemporaryError (X, Y)
    9. if esum > eps
    10.     kv = [], iT = []
    11.     for i=1..T
    12.         for k=1..K
    13.             if Ev_time(i, k) > eps
    14.                 kv[i, k]= k, iT[i]=i
    15.             end if
    16.         end for
    17.     end for
    18. iT= Δtmin iT
end function
    
```

Результаты и обсуждение

Для апробирования метода выявления аномалий в экономических показателях была разработана программа в среде MatLab, в которой был реализован DSC-AE и функции, представленные в листингах 1–3. Так как получение экономических данных, в полном объеме отражающих деятельность производственной организации с дискретизацией на длительных временных интервалах, сталкивается с организационными трудностями и коммерческой тайной, то на данном этапе исследований в качестве экономических показателей (исходных данных) были использованы котировки золота, платины (для матрицы D_{normal}) и курсы американского доллара и евро к рублю (для матрицы Q_{normal}) за период с 20 ноября 2020 года по 20 ноября 2025 года, доступные на сайте InvestFunds1. Интервал дискретизации для всех выбранных показателей одинаков и составляет один

день, поэтому повторную дискретизацию, предусмотренную в описываемом методе, делать не нужно.

Динамика нормированных к диапазону от 0 до 1 показателей за указанный период представлена на рисунке 6. Пунктирные вертикальные линии на нем соответствуют размеру окна при $h = 103$, из которых формируются сигнатуры.

Последнее окно проходит весь набор данных, от конца к началу, сдвигаясь каждый раз на один отсчет, поэтому всего обучающих примеров будет 1600 для каждого показателя (промежуточные вертикальные линии для каждого i на рисунке 6 не показаны, чтобы не загромождать рисунок).

На рисунке 7 показаны примеры формируемых сигнатур анализируемых показателей для номеров отсчетов времени с 297 по 400. Видно, что чередование темных (характеризуют большие значения показателей) и более светлых (малые значения) полос на них имеет схожие черты, что может быть использовано DSC-AE при выявлении аномальных данных в одном или нескольких показателях.

¹ Независимый источник данных для частного инвестора в России. URL: <https://investfunds.ru> (дата обращения: 28.11.2025).




Рис. 6. Динамика анализируемых показателей

Fig. 6. Dynamics of the analyzed indicators




Рис. 7. Примеры сигнатур анализируемых показателей

Fig. 7. Examples of signatures of analyzed indicators

Обучение DSC-AE проводилось в течение ста эпох на персональном компьютере с процессором Intel (R) Core (TM) i5–12400 (2.50 GHz), 16Gb RAM, без дискретной видеокарты. Для настройки параметров нейронной сети применялся стохастический градиентный спуск с импульсом (параметр оптимизатора устанавливался в значение 'sgdm'). В нем учитывается как направление градиентов, так и выпуклость минимизируемой функции, что ускоряет процесс обучения [24]. Обучающая выборка составляла 1300 примеров, выборка для валидации содержала 300 примеров, каждый из примеров имел вид (3), представленный в виде тепловой матрицы (сигнатуры). Среднеквадратичная ошибка на валидационной выборке в конце обучения составила $eps = 0,322$.

Для создания рабочей выборки был дополнительно скачан набор тех же показателей для временного интервала с 3 февраля по 19 ноября 2020 года. Были сформированы сигнатуры данных показателей для $h = 103$ (сигнатура должна иметь ту же форму, что и при обучении DSC-AE, в противном случае требуется его дообучение для новой формы). Далее был применен AE и рассчитана ошибка (4), значение которой составило 0,296, что

меньше $eps = 0,322$ – это дает основание сделать вывод об отсутствии аномалий во временном окне, определяемом сигнатурой.

Для одного канала (всего в примере их четыре), стоимости золота, были введены искусственно искаженные данные, имитирующие аномалии двух разных типов: в форме увеличения разброса значений стоимости золота (кривая *Gold anomal₁*) и, наоборот, плавного, без резких скачков, изменения стоимости (*Gold anomal₂*). Эти аномалии отражены на рисунке 8.

На рисунке 9 показаны сигнатуры рабочих данных (стоимость золота) без аномалий (*Gold normal*) и с указанными выше добавленными аномалиями. Визуальный анализ сигнатур показывает различие в текстуре нормальных и аномальных данных, что должно быть определено DSC-AE.

Тепловые карты ошибок воспроизведения DSC-AE входных данных по каналу «золото» показаны на рисунке 10, из которого следует, что хотя внешний вид карт похож друг на друга, диапазон отображаемых значений ошибок у них разный (о чем свидетельствуют шкалы рядом с изображениями) – для нормальных данных максимальная ошибка находится




Рис. 8. Аномалии, добавленные к данным рабочей выборки
 Fig. 8. Anomalies added to the working sample data




Рис. 9. Сигнатуры нормальных и аномальных данных
 Fig. 9. Signatures of normal and abnormal data




Рис. 10. Сигнатуры ошибок для нормальных и аномальных данных
 Fig. 10. Error signatures for normal and abnormal data

в пределах до 0,25, в то время как для данных с добавленными аномалиями она находится в диапазоне до 0,6. Это обстоятельство позволяет применять (4) и (5)

как индикаторы наличия аномалий, что реализуется функцией AD в листинге 3.

Для сравнительной оценки качества выявления аномалий с помощью

предложенного метода и некоторыми SOTA-моделями (State-Of-The-Art) необходимо учитывать, что они разрабатываются для конкретных предметных областей и формата анализируемых данных, поэтому не всегда удается найти бенчмарки, адаптированные под модель, реализующую разработанный метод.

Поэтому было предложено провести сравнение DSC-AE с одной из современных моделей STAS/SFAS (Space-Time Anomaly Score/Statistical Feature Anomaly Score) на синтетическом наборе данных Waves (WVS), описание которой вместе с описанием самой модели приводится в [25]. WVS состоит из десяти временных рядов, сгруппированных по общей частоте, а аномалии вводятся через определенные временные интервалы путем добавления синусоид с отклоняющимися частотами и введением выбросов с постоянными значениями. В [25] STAS/SFAS сравнивается с моделью OmniAnomaly [26], поэтому OmniAnomaly также представлена в таблице результатов эксперимента (табл. 1).

Качество моделей в [25] оценивалось по метрике F1, применяемой при оценке классификаторов, поэтому задача выявления аномалий рассматривалась как задача классификации: задавался интервал h , и если на нем модели обнаруживали аномалии, то вся выборка длиной h от-

носилась к классу «аномальные данные», в противном случае – к классу «нормальные данные».

Сравнение моделей проводилось при следующих значениях параметра h , определяющего размер окна выбора данных в DSC-AE: 10, 20, 30, 40 и 50. В таблице 1 представлены результаты эксперимента, однако в ней историческая глубина указана как $2h$, что обусловлено другим толкованием этого параметра в [25], где под h понимается номер максимально удаленных от текущего момента времени отсчета, а в DSC-AE, как ранее отмечалось, при заданном h фактически историческая глубина анализируемых данных будет составлять $2h$.

Анализ данных таблицы 1 позволяет сделать вывод, что модель DSC-AE при росте h показывает результат, близкий к STAS/SFAS, при этом опережая OmniAnomaly, что свидетельствует о хорошей работоспособности предложенного метода, сопоставимого с современными моделями, имеющими более сложную архитектуру и, следовательно, более высокие требования к аппаратному обеспечению.

Поэтому DSC-AE может быть применен в разведочном анализе данных, на первых этапах исследования экономических показателей организации, хотя усложнение архитектуры автокодировщика может повысить точность модели

Таблица 1. Метрика F1 моделей на наборе WVS

Table 1. F1 metrics of models on the WVS dataset

Модель <i>Model</i>	$2h$				
	20	40	60	80	100
STAS/SFAS	0,86	0,86	0,87	0,88	0,91
OmniAnomaly	0,52	0,59	0,62	0,60	0,61
DSC-AE	0,48	0,57	0,65	0,77	0,83

DSC-AE и сделать ее применение обоснованным и при более глубоком анализе данных.

Заключение

Применение искусственной нейронной сети с архитектурой автокодировщика, использующего глубинно-разделимые свертки, показало свою работоспособность в задаче выявления аномалий в экономических показателях. Глубинно-разделимые свертки позволяют настраивать

канальные сверточные фильтры автокодировщика независимо друг от друга, обеспечивая более высокую эффективность выявления глубинных закономерностей в данных и применение их при детектировании аномалий.

Предложенный метод DSC-AE может быть применен в разведочном анализе данных, характеризующих различные экономические объекты, в том числе в алгоритмическом обеспечении систем поддержки предпринимательских решений.

Список литературы

1. Ikeda Y., Hadfi R., Ito T., Fujihara A. Anomaly detection and facilitation AI to empower decentralized autonomous organizations for secure crypto-asset transactions // *AI & Society*. 2025. Vol. 40. No. 5. P. 3999–4010. DOI: 10.1007/s00146-024-02166-w.
2. Рубин Ю. Б. О проекте профессионального стандарта «Предприниматель (Специалист по решению предпринимательских задач)» // *Современная конкуренция*. 2022. Т. 16. № 1. С. 5–28. DOI: 10.37791/2687-0649-2022-16-1-5-28.
3. Курнышева И. П. Конкурентная политика в системе стратегического планирования // *Современная конкуренция*. 2020. Т. 14. № 3 (79). С. 28–40. DOI: 10.37791/1993-7598-2020-14-3-28-40.
4. Cao Y. Using AI and big data analytics to support entrepreneurial decisions in the digital economy // *Scientific Reports*. 2025. Vol. 15. Article 36933. DOI: 10.1038/s41598-025-20871-4.
5. Coil C., Faber K., Sniezynski B., Corizzo R. Distance-based change point detection for novelty detection in concept-agnostic continual anomaly detection // *Journal of Intelligent Information Systems*. 2025. DOI: 10.1007/s10844-025-00949-1.
6. Rahmati F., Gharaei R. H., Nezamabadi-pour H. ARDOD: Adaptive radius density-based outlier detection // *Evolutionary Intelligence*. 2024. Vol. 17. P. 3707–3722. DOI: 10.1007/s12065-024-00953-4.
7. Zahoor A., Abbasi W., Babar M. Z., Aliohani A. Robust IoT security using isolation forest and one class SVM algorithms // *Scientific Reports*. 2025. Vol. 15. Article 36586. DOI: 10.1038/s41598-025-20445-4.
8. Bhatia S., Jain A., Li P., Kumar R., Hooi B. MStream: Fast anomaly detection in multi-aspect streams // *Proceedings of the Web Conference 2021 (WWW '21)*. 2021. P. 3371–3382. DOI: 10.1145/3442381.3450023.
9. Powers H., Edoh K. Outlier detection variational autoencoder // *Neural Computing and Applications*. 2025. Vol. 37. P. 16871–16882. DOI: 10.1007/s00521-025-11357-5.
10. Sarkar S., Melnykov V. Detecting anomalies in European trade data using directed weighted multilayer dynamic networks // *Journal of Classification*. 2025. Vol. 42. P. 544–564. DOI: 10.1007/s00357-025-09502-9.
11. Hasan F., Al-Najjar B. Calendar anomalies and dividend announcements effects on the stock markets returns // *Review of Quantitative Finance and Accounting*. 2025. Vol. 64. P. 829–859. DOI: 10.1007/s11156-024-01321-0.
12. Zhou Z., Wu J., Huang P., Xiong X. Cross-sectional anomalies and conditional asset pricing models based on investor sentiment: Evidence from the Chinese stock market // *Financial Innovation*. 2025. Vol. 11. Article 103. DOI: 10.1186/s40854-025-00774-z.
13. Yahia A., Mouhssine Y., El Alaoui A., El Alaouiet S. O. Exploring machine learning-based methods for anomalies detection: Evidence from cryptocurrencies // *International Journal of Data Science and Analytics*. 2025. Vol. 20. P. 3951–3964. DOI: 10.1007/s41060-024-00703-w.
14. Zhu Y., Zhang Y., Zhang C., Zhang B., Wang H., Feng S. Detection of false data injection in electric energy metering platforms using gradient lifting decision trees and MLP neural networks // *Discover Applied Sciences*. 2025. Vol. 7. Article 42. DOI: 10.1007/s42452-024-06450-8.

15. *Liguori A., Markovic R., Dam T. T. H., Frisch J., Treeck C., Causone F.* Indoor environment data time-series reconstruction using autoencoder neural networks // *Building and Environment*. 2021. Vol. 191. Article 107623. DOI: 10.1016/j.buildenv.2021.107623.
16. *Zhu Y., Katariya S., Nowak R.* Robust outlier arm identification // *arXiv*. 2020. DOI: 10.48550/arXiv.2009.09988.
17. *Sukharev I., Shumovskaia V., Fedyanin K., Panov M., Berestnev D.* EWS-GCN: Edge weight-shared graph convolutional network for transactional banking data // *arXiv*. 2020. DOI: 10.48550/arXiv.2009.14588.
18. *Li Z., Zhao Y., Botta N., Ionescu C., Hu X.* COPOD: Copula-based outlier detection // *Proceedings of the International Conference on Data Mining (ICDM)*. 2020. P. 1118–1123. DOI: 10.1109/ICDM50108.2020.00135.
19. *Hinton G. E., Salakhutdinov R. R.* Reducing the dimensionality of data with neural networks // *Science*. 2006. Vol. 313. No. 5786. P. 504–507. DOI: 10.1126/science.1127647.
20. *Chollet F.* Xception: Deep learning with depthwise separable convolutions // *Proceedings of the Conference on Computer Vision and Pattern Recognition*. 2017. DOI: 10.1109/CVPR.2017.195.
21. *Шолле Ф.* Глубокое обучение на Python. – 2-е изд., междунар. – СПб.: Питер, 2023. – 576 с.
22. *Пучков А.Ю., Дли М.И., Василькова М.А., Прохимнов Н.Н.* Метод прогнозирования оттока клиентов банка на основе ансамблевой модели машинного обучения // *Прикладная информатика*. 2024. Т. 19. № 1. С. 5–27. DOI: 10.37791/2687-0649-2024-19-1-5-27.
23. *Puchkov A., Dli M., Bobkov V.* Ensemble neural network 3D-CNN and LSTM in the problem of assessing the state of a technological system for processing ore waste // *Proceedings of the International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*. 2024. P. 1001–1006. DOI: 10.1109/ICIEAM60818.2024.10554041.
24. *Абдулкадиров Р.И., Ляхов П.А.* Новый подход к обучению нейронных сетей с помощью натурального градиентного спуска с импульсом на основе распределений Дирихле // *Компьютерная оптика*. 2023. Т. 47. № 1. С. 160–169. DOI: 10.18287/2412-6179-CO-1147.
25. *Shimillas C., Malialis K., Fokianos K., Polycarpou M. M.* Transformer-based multivariate time series anomaly localization // *Proceedings of the Symposium on Computational Intelligence on Engineering/Cyber Physical Systems (CIES)*. 2025. DOI: 10.1109/CIES64955.2025.11007637.
26. *Su Y., Zhao Y., Niu C., Liu R., Sun W., Pei D.* Robust anomaly detection for multivariate time series through stochastic recurrent neural network // *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19)*. 2019. P. 2828–2837. DOI: 10.1145/3292500.3330672.

Сведения об авторах

Минин Владимир Сергеевич, ORCID 0009-0002-0435-9806, директор ООО «ВИСОМ», Смоленск, Россия, Mininvssm@yahoo.com

Кириллова Елена Александровна, ORCID 0000-0001-7046-3316, докт. экон. наук, доцент, профессор, кафедры информационных технологий в экономике и управлении, филиал Национального исследовательского университета «МЭИ» в г. Смоленске, Смоленск, Россия, kirillova.el.al@yandex.ru

Какатунова Татьяна Валентиновна, ORCID 0000-0003-3827-232X, докт. экон. наук, профессор, профессор кафедры информационных технологий в экономике и управлении, филиал Национального исследовательского университета «МЭИ» в г. Смоленске, Смоленск, Россия, tatjank@yandex.ru

Филимонова Елена Викторовна, ORCID 0000-0002-9791-7610, канд. пед. наук, доцент, кафедра цифровой экономики, Университет «Синергия», Москва, Россия, elena-gamilton@mail.ru

Поддержка исследований

Работа выполнена в рамках государственного задания, проект № FSWF-2023–0012.

Статья поступила 17.06.2025, рассмотрена 03.07.2025, принята 18.09.2025

References

1. *Ikeda Y., Hadfi R., Ito T., Fujihara A.* Anomaly detection and facilitation AI to empower decentralized autonomous organizations for secure crypto-asset transactions. *AI & Society*, 2025, vol.40, no.5, pp.3999-4010. DOI: 10.1007/s00146-024-02166-w.

2. Rubin Yu. About the Professional Standard Draft “Entrepreneur (Specialist in Solving Entrepreneurial Goals)”. *Sovremennaya konkurentsya=Journal of Modern Competition*, 2022, vol.16, no.1, pp.5-28 (in Russian). DOI: 10.37791/2687-0649-2022-16-1-5-28.
3. Kurnisheva I. Competitive policy in the strategic planning system. *Sovremennaya konkurentsya=Journal of Modern Competition*, 2020, vol.14, no.3(79), pp.28-40 (in Russian). DOI: 10.37791/1993-7598-2020-14-3-28-40.
4. Cao Y. Using AI and big data analytics to support entrepreneurial decisions in the digital economy. *Scientific Reports*, 2025, vol.15, article 36933. DOI: 10.1038/s41598-025-20871-4.
5. Coil C., Faber K., Sniezynski B., Corizzo R. Distance-based change point detection for novelty detection in concept-agnostic continual anomaly detection. *Journal of Intelligent Information Systems*, 2025. DOI: 10.1007/s10844-025-00949-1.
6. Rahmati F., Gharaei R. H., Nezamabadi-pour H. ARDOD: Adaptive radius density-based outlier detection. *Evolutionary Intelligence*, 2024, vol.17, pp.3707-3722. DOI: 10.1007/s12065-024-00953-4.
7. Zahoor A., Abbasi W., Babar M. Z., Aliohani A. Robust IoT security using isolation forest and one class SVM algorithms. *Scientific Reports*, 2025, vol.15, article 36586. DOI: 10.1038/s41598-025-20445-4.
8. Bhatia S., Jain A., Li P., Kumar R., Hooi B. MStream: Fast anomaly detection in multi-aspect streams. *Proceedings of the Web Conference 2021 (WWW '21)*, 2021, pp.3371-3382. DOI: 10.1145/3442381.3450023.
9. Powers H., Edoh K. Outlier detection variational autoencoder. *Neural Computing and Applications*, 2025, vol.37, pp.16871-16882. DOI: 10.1007/s00521-025-11357-5.
10. Sarkar S., Melnykov V. Detecting anomalies in European trade data using directed weighted multilayer dynamic networks. *Journal of Classification*, 2025, vol.42, pp.544-564. DOI: 10.1007/s00357-025-09502-9.
11. Hasan F., Al-Najjar B. Calendar anomalies and dividend announcements effects on the stock markets returns. *Review of Quantitative Finance and Accounting*, 2025, vol.64, pp.829-859. DOI: 10.1007/s11156-024-01321-0.
12. Zhou Z., Wu J., Huang P., Xiong X. Cross-sectional anomalies and conditional asset pricing models based on investor sentiment: Evidence from the Chinese stock market. *Financial Innovation*, 2025, vol.11, article 103. DOI: 10.1186/s40854-025-00774-z.
13. Yahia A., Mouhssine Y., El Alaoui A., El Alaouiet S. O. Exploring machine learning-based methods for anomalies detection: Evidence from cryptocurrencies. *International Journal of Data Science and Analytics*, 2025, vol.20, pp.3951-3964. DOI: 10.1007/s41060-024-00703-w.
14. Zhu Y., Zhang Y., Zhang C., Zhang B., Wang H., Feng S. Detection of false data injection in electric energy metering platforms using gradient lifting decision trees and MLP neural networks. *Discover Applied Sciences*, 2025, vol.7, article 42. DOI: 10.1007/s42452-024-06450-8.
15. Liguori A., Markovic R., Dam T. T. H., Frisch J., Treeck C., Causone F. Indoor environment data time-series reconstruction using autoencoder neural networks. *Building and Environment*, 2021, vol.191, article 107623. DOI: 10.1016/j.buildenv.2021.107623.
16. Zhu Y., Katariya S., Nowak R. Robust outlier arm identification. *arXiv*, 2020. DOI: 10.48550/arXiv.2009.09988.
17. Sukharev I., Shumovskaia V., Fedyanin K., Panov M., Berestnev D. EWS-GCN: Edge weight-shared graph convolutional network for transactional banking data. *arXiv*, 2020. DOI: 10.48550/arXiv.2009.14588.
18. Li Z., Zhao Y., Botta N., Ionescu C., Hu X. COPOD: Copula-based outlier detection. *Proceedings of the International Conference on Data Mining (ICDM)*, 2020, pp.1118-1123. DOI: 10.1109/ICDM50108.2020.00135.
19. Hinton G. E., Salakhutdinov R. R. Reducing the dimensionality of data with neural networks. *Science*, 2006, vol.313, no.5786, pp.504-507. DOI: 10.1126/science.1127647.
20. Chollet F. Xception: Deep learning with depthwise separable convolutions. *Proceedings of the Conference on Computer Vision and Pattern Recognition*, 2017. DOI: 10.1109/CVPR.2017.195.
21. Scholle F. *Glubokoe obuchenie na Python* [Deep learning with Python]. 2nd edition, intern. St. Petersburg, Piter Publ., 2023, 576 p.
22. Puchkov A., Dli M., Vasilkova M., Prokimnov N. A method for predicting bank customer churn based on an ensemble machine learning model. *Prikladnaya informatika=Journal of Applied Informatics*, 2024, vol.19, no.1, pp.5-27 (in Russian). DOI: 10.37791/2687-0649-2024-19-1-5-27.
23. Puchkov A., Dli M., Bobkov V. Ensemble neural network 3D-CNN and LSTM in the problem of assessing the state of a technological system for processing ore waste. *Proceedings of the International Conference*

- on Industrial Engineering, Applications and Manufacturing (ICIEAM), 2024, pp.1001-1006. DOI: 10.1109/ICIEAM60818.2024.10554041.
24. Abdulkadirov R.I., Lyakhov P.A. A new approach to training neural networks using natural gradient descent with momentum based on Dirichlet distributions. *Komp'yuternaya optika*=Computer Optics, 2023, vol.47, no.1, pp.160-169 (in Russian). DOI: 10.18287/2412-6179-CO-1147.
25. Shimillas C., Malialis K., Fokianos K., Polycarpou M.M. Transformer-based multivariate time series anomaly localization. Proceedings of the Symposium on Computational Intelligence on Engineering/ Cyber Physical Systems (CIES), 2025. DOI: 10.1109/CIES64955.2025.11007637.
26. Su Y., Zhao Y., Niu C., Liu R., Sun W., Pei D. Robust anomaly detection for multivariate time series through stochastic recurrent neural network. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19), 2019, pp.2828-2837. DOI: 10.1145/3292500.3330672.

About the authors

Vladimir S. Minin, ORCID 0009-0002-0435-9806, Director of VISOM LLC, Smolensk, Russia, Mininvssm@yahoo.com

Elena A. Kirillova, ORCID 0000-0001-7046-3316, Dr. Sci. (Econ.), Associate Professor, Professor, Information Technology in Economics and Management Department, Branch of the National Research University "MPEI" in Smolensk, Smolensk, Russia, kirillova.el.al@yandex.ru

Tatyana V. Kakatunova, ORCID 0000-0003-3827-232X, Dr. Sci. (Econ.), Professor, Information Technology in Economics and Management Department, Branch of the National Research University "MPEI" in Smolensk, Smolensk, Russia, tatjank@yandex.ru

Elena V. Filimonova, ORCID 0000-0002-9791-7610, Cand. Sci. (Ped.), Associate Professor, Digital Economy Department, Synergy University, Moscow, Russia, elena-gamilton@mail.ru

Research Support

The reported study was funded in accordance with the State assignment, the project no. FSWF-2023-0012.

Received 17.06.2025, reviewed 03.07.2025, accepted 18.09.2025