УДК 004.9
DOI: 10.26102/2310-6018/2026.62.11.007

Реконструктивное моделирование многомерных временных рядов для детектирования неявных аномалий в цензурированных данных

Е.В. Сафонова✉, Н.Д. Алиева, М.В. Щербаков

Волгоградский государственный технический университет, Волгоград, Российская Федерация

Резюме. Актуальность исследования обусловлена проблемой обнаружения аномалий в гетерогенных распределенных системах в условиях неполноты журналов событий и отсутствия размеченных данных. Согласно стандартам надежности (ГОСТ 27.002-2015, IEC 60050-191, IEC 60300-3-11, ISO/TR 12489), скрытый (латентный) отказ трактуется как состояние, не обнаруживаемое штатными методами и средствами контроля и диагностирования при нормальной эксплуатации. В современных программно-аппаратных комплексах к таким штатным средствам относятся сенсоры и логи системы управления. Однако на практике возникает специфический класс деградаций: оборудование физически деградирует, что регистрируется многомерными временными рядами сенсоров, но отсутствует в журналах событий системы. Поскольку данная ситуация выходит за рамки классического определения скрытого отказа, данная статья направлена на восполнение терминологического пробела – введено новое понятие «неявной аномалии». Предложен метод реконструктивного моделирования многомерных временных рядов для детектирования неявных аномалий на основе LSTM автоэнкодера с последующей верификацией через анализ плотности отклонений во временном окне. Проблема пропущенных событий интерпретирована через призму теории цензурированных данных. Экспериментальная проверка на синтетических многомерных временных рядах продемонстрировала способность метода обнаруживать интервалы деградации оборудования, не зафиксированные в логах системы. Материалы статьи представляют практическую ценность для разработчиков систем предиктивной аналитики и мониторинга, поскольку предложенный подход позволяет повысить полноту обнаружения инцидентов в условиях неполной наблюдаемости объекта управления.

Ключевые слова: гетерогенные распределенные системы, реконструктивное моделирование, неявные аномалии, цензурированные данные, многомерные временные ряды.

Для цитирования: Сафонова Е.В., Алиева Н.Д., Щербаков М.В. Реконструктивное моделирование многомерных временных рядов для детектирования неявных аномалий в цензурированных данных. *Моделирование, оптимизация и информационные технологии.* 2026;14(11). URL: https://moitvivt.ru/ru/journal/article?id=2617 DOI: 10.26102/2310-6018/2026.62.11.007

Reconstructive modeling of multivariate time series for detecting implicit anomalies in censored data

E.V. Safonova✉, N.D. Alieva, M.V. Shcherbakov

Volgograd State Technical University, Volgograd, the Russian Federation

Abstract. The relevance of the research is driven by the problem of anomaly detection in heterogeneous distributed systems under conditions of incomplete event logs and the absence of labeled data. According to reliability standards (GOST 27.002-2015, IEC 60050-191, IEC 60300-3-11, ISO/TR 12489), a hidden (latent) failure is defined as a state undetected by standard control and diagnostic methods during normal operation. In modern hardware-software complexes, such standard means include sensors and control system logs. However, in practice, a specific class of degradations arises:

© Сафонова Е.В., Алиева Н.Д., Щербаков М.В., 2026

equipment undergoes physical degradation captured by multidimensional sensor time series yet entirely absent from the system's event logs. Since this scenario falls outside the classical definition of a hidden failure, this article aims to bridge the terminological gap by introducing the novel concept of an "implicit anomaly". A reconstructive modeling method for multidimensional time series is proposed, based on an LSTM autoencoder with subsequent verification through deviation density analysis within a time window. The problem of missing events is interpreted through the lens of censored data theory. Experimental validation on synthetic multidimensional time series demonstrated the method's ability to detect equipment degradation intervals unrecorded in system logs. The materials of the article are of practical value for developers of predictive analytics and monitoring systems, as the proposed approach increases the completeness of incident detection under conditions of partial observability of the controlled system.

Keywords: heterogeneous distributed systems, reconstructive modeling, implicit anomalies, censored data, multivariate time series.

For citation: Safonova E.V., Alieva N.D., Shcherbakov M.V. Reconstructive modeling of multivariate time series for detecting implicit anomalies in censored data. *Modeling, Optimization and Information Technology.* 2026;14(11). (In Russ.). URL: https://moitvivt.ru/ru/journal/article?id=2617 DOI: 10.26102/2310-6018/2026.62.11.007

Введение

Современные инфраструктурные и производственные системы функционируют как гетерогенные распределенные системы (ГРС) [1, 2]. Их надежность критически зависит от способности своевременно выявлять отклонения в работе оборудования на основе данных сенсоров. Для эксплуатации важно не только регистрировать уже произошедшие отказы, но и выявлять изменение режима работы оборудования до появления явной записи об аварийном состоянии. На практике эта задача осложняется качеством исходных данных. Отказы возникают сравнительно редко, а сведения о них накапливаются неравномерно: часть событий подробно отражена в журнале событий системы управления, часть фиксируется только косвенно, а отдельные изменения режима вообще не получают необходимой метки, что не позволяет применять методы обучения на размеченных данных. Особенно важны случаи, когда отказы не фиксируются. Это приводит к появлению цензурированных данных, когда момент наступления события известен с точностью до интервала, либо событие не зафиксировано вовсе при наличии физических признаков отказа. Понятие цензурированных наблюдений является базовым для анализа надежности и выживаемости [3]. Методы машинного обучения для задач анализа выживаемости при неполной информации проработаны в трудах Л.В. Уткина и его коллег [4].

Согласно стандартам надежности (ГОСТ 27.002-2015, IEC 60050-191, IEC 60300-3-11, ISO/TR 12489), скрытый (латентный) отказ трактуется как состояние, не обнаруживаемое штатными средствами контроля и диагностирования при нормальной эксплуатации и выявляемое только при проведении функциональных тестов либо по факту отказа системы. В контексте ГРС к таким штатным средствам относятся сенсоры и журналы событий системы управления. Однако на практике возникает специфический класс состояний, не описываемый данным определением: физическая деградация оборудования регистрируется многомерными временными рядами сенсоров, но полностью отсутствует в журнале событий системы управления. Поскольку в этом случае штатные средства контроля фиксируют отклонение, формально данное состояние не является скрытым отказом в терминах стандарта. Для восполнения терминологического пробела в настоящей работе вводится понятие неявной аномалии.

Chandola, Banerjee и Kumar определяют обнаружение аномалий как задачу «идентификации паттернов в данных, которые не соответствуют ожидаемому

поведению» [5]. Blázquez-García и соавторы выделяют отдельный класс задач для временных рядов, подчёркивая, что «временная природа данных добавляет сложность: аномалия должна рассматриваться в контексте предшествующих и последующих наблюдений» [6]. В данном разделе приводится анализ применимости существующих методов к решаемой задаче выявления неявных аномалий в условиях цензурированных данных.

Статистические методы, в том числе анализ главных компонент (PCA), предполагают линейность и стационарность данных, чувствительны к выбросам в обучающей выборке, что критично при наличии пропущенных событий в истории [7].

Методы обнаружения точек изменения, включая CUSUM и Bayesian Online Change Point Detection (BOCPD) рассматриваются в обзорах методов анализа аномалий временных рядов [6] и ориентированы на выявление резких переходов между режимами. Их применение осложняется, когда деградация развивается постепенно и сопровождается шумом.

Методы кластеризации состояний, такие как скрытые марковские модели (HMM) и смесь гауссов (GMM), моделируют временную структуру, могут выделять различные режимы работы, но требуют предположение о распределении данных и сложно масштабируются на многомерные данные с долговременными зависимостями [6]. Для высокоразмерных данных вероятностное моделирование часто объединяют с обучением нелинейного представления; примером такого подхода является Deep Autoencoding Gaussian Mixture Model (DAGMM) в котором «энкодер сжимает вход в компактное представление, а смесь гауссов оценивает плотность в скрытом пространстве» [8], что позволяет избежать отдельного этапа предобучения.

One-Class SVM относится к классическим одноклассовым подходам обнаружения аномалий [5], а Isolation Forest строит оценку аномальности на основе «изоляции наблюдений случайными разбиениями: аномальные точки изолируются за меньшее число разбиений, чем нормальные» [9]. Оба подхода не требуют примеров всех возможных типов отказов, однако при анализе временных рядов качество результата зависит от способа формирования признаков и представления временного контекста [6].

Методы на основе прогнозирования фиксируют отклонение как расхождение между ожидаемым и наблюдаемым значением [10], но при смене допустимого режима это расхождение также может возрастать, что затрудняет отделение аномалии от нормального перехода между режимами.

Глубокие модели позволяют учитывать нелинейную структуру многомерных данных. В обзорах временных рядов рассматриваются, в частности, автоэнкодерные и вариационные реконструктивные подходы [6]; для многомерного обнаружения аномалий применяются GAN-модели, в которой «генератор моделирует нормальные временные ряды, а дискриминатор оценивает вероятность того, что последовательность является аномальной» [11], Deep SVDD – метод, «обучающий нейронную сеть отображать данные в гиперсферу минимального объема в скрытом пространстве» [12] и робастные глубокие автоэнкодеры, рассчитанные на загрязненные обучающие данные [7].

Архитектуры на основе трансформеров, в частности, Anomaly Transformer, где введено понятие «association discrepancy» – расхождения между априорным и апостериорным распределениями ассоциаций временных точек, что позволяет отличать аномалии от простых выбросов [13], и TranAD, использующий «механизм внимания с фокусировкой на реконструкцию для усиления реконструкционной ошибки при аномальных паттернах» [14], также применяются к многомерным временным рядам. Их использование связано с более сложной настройкой и заметными вычислительными

затратами; кроме того, при неполной разметке сохраняется отдельная проблема верификации обнаруженных интервалов.

Таким образом, существующие модели не решают задачу детектирования неявных аномалий в цензурированных данных.

Целью данной работы является разработка метода реконструктивного моделирования многомерных временных рядов для выявления неявных аномалий на сенсорном уровне ГРС в условиях неполноты журналов событий, когда отсутствие записи об отказе не используется как метка нормы.

Материалы и методы

Формальная модель и постановка задачи. Пусть многомерный временной ряд наблюдений на сенсорном уровне ГРС представлен в виде:

$$X = \{x_t\}_{t=t_0}^{t_k}, \quad (1)$$

где $x_t \in \mathbb{R}^d$ – вектор показаний d датчиков в момент времени t.

Система ведет журнал событий $\mathcal{L} = \{(t_j, s_j)\}$, где t_j – временная метка, $s_j \in \{Running, Idle, Failure\}$ – статус события. Запись со статусом Failure рассматривается как зарегистрированный отказ.

В анализе надежности цензурированными называют наблюдения, для которых сведения о наступлении события представлены не полностью [3]:

1. Интервальное цензурирование**,** если известно, что событие произошло в интервале $[t_{start}, t_{end}]$, но точный момент неизвестен.

2. Левостороннее цензурирование (пропущенные события), если известно, что событие произошло до известного момента наблюдения, но точное время события неизвестно.

В контексте мониторинга ГРС формализуется задача выявления неявной аномалии в условиях, если событие физически произошло и сигналы датчиков его зафиксировали, но в журнале $\mathcal{L}$ отсутствует соответствующая запись.

ξ будем считать неявной аномалией, если выполняется условие:

$$\xi \text{ is implicit } \Leftrightarrow \begin{cases} \exists t^*: X(t^*) \text{ содержит устойчивое отклонение от нормы} \\ \wedge \ \nexists (t_j, s_j) \in \mathcal{L}: \mid t_j - t^* \mid \leq \delta \wedge s_j = \{Failure\} \end{cases}, \quad (2)$$

где δ – допустимое временное окно сопоставления сенсорного отклонения с записью Failure в журнале.

Для обучения модели используется референтная выборка исторических наблюдений D_{ref}. В реальной системе нельзя гарантировать, что все ее фрагменты соответствуют нормальному состоянию. Поэтому референтная выборка считается преимущественно нормальной, но допускается присутствие небольшой доли неучтенных аномалий:

$$P(x \in D_{ref} \mid x \text{ is anomaly}) \leq \varepsilon. \quad (3)$$

Параметр ε задает верхнюю оценку допустимой доли неучтенных аномальных фрагментов в референтной выборке.

Метод детектирования неявных аномалий. Предложенный метод основан на гипотезе, что физическая деградация оборудования порождает устойчивые коллективные отклонения в сигналах датчиков, даже при отсутствии явной метки статуса в журнале событий.

Для LSTM-автоэнкодера исходный ряд разбивается на перекрывающиеся последовательности (окна) W_t. Модель M обучается восстанавливать входное окно.

Функция потерь имеет вид:

$$\mathcal{J} = \frac{1}{N}\sum_{t=1}^{N} \| W_t - M(W_t) \|^2, \quad (4)$$

где W_t – входное окно; $M(W_t)$ – восстановленная моделью последовательность; N – число обучающих окон.

Модель обучается воспроизводить нормальные паттерны. Высокая ошибка указывает на нетипичный режим, но сама по себе еще не определяет аномалии, так как кратковременный всплеск может быть вызван шумом или единичным выбросом.

Для каждого окна вычисляется ошибка реконструкции $e(t)$.

$$e(t) = \| W_t - M(W_t) \|^2. \quad (5)$$

Бинарная метка точечной аномалии определяется как:

$$A_{point}(t) = \mathbb{I}(e(t) > \theta), \quad (6)$$

где $\mathbb{I}(\cdot)$ – индикаторная функция, а θ – порог аномальности.

Одиночные превышения порога не объединяются с отказом автоматически. Для выделения аномалий вводится критерий плотности во временном окне:

$$\rho(t) = \frac{1}{K}\sum_{\tau=t-K+1}^{t} A_{point}(\tau), \quad (7)$$

где K – длина окна оценки плотности. Для момента t рассматривается интервал $I_t = [t - K + 1, t]$.

Интервал I_t рассматривается как неявная аномалия, если плотность превышений достаточна и этот интервал не относится к окрестности уже зарегистрированного отказа:

$$A_{implicit}(t) = \mathbb{I}\left(\rho(t) > \theta_{density}\right) \wedge \neg A_{explicit}(t \pm T_{exclude}), \quad (8)$$

где $\theta_{density}$ – порог плотности; $A_{explicit}$ – известные метки отказов из логов $\mathcal{L}$; $T_{exclude}$ – зона исключения вокруг известных событий.

Таким образом, метод ретроспективно выявляет интервалы времени, где сигнал ведет себя как при отказе, но в журнале событий отсутствует соответствующая запись.

Результаты

Для оценки эффективности предложенного метода были созданы два синтетических датасета – machine_dataset_etalon.csv и machine_dataset.csv. Оба набора данных генерируются с помощью Python-скриптов и моделируют работу 10 единиц промышленного оборудования, функционирующих в непрерывном режиме. Данные представляют собой многомерные временные ряды пяти сенсоров: температуры, вибрации, влажности, давления и энергопотребления. Параметры генерации сопоставлены со статистическими характеристиками датасета NASA C-MAPSS[1] по следующим критериям: диапазоны значений сенсоров соответствуют диапазонам для турбовентиляторных двигателей; длительность окна деградации (60 минут); корреляционная структура между сенсорами отражает физические зависимости, наблюдаемые в реальных системах. Такое сопоставление обеспечивает адекватность синтетических данных для тестирования методов обнаружения аномалий на этапе

[1] Saxena A., Goebel K. *Turbofan Engine Degradation Simulation Data Set.* NASA Prognostics Data Repository. URL: https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/ (дата обращения: 12.08.2026).

разработки алгоритма, хотя и не заменяет прямую валидацию на реальных наборах данных.

Эталонный набор охватывает период с 1 января по 31 марта 2025 года с минутным шагом. Статус оборудования принимает значения Running, Idle и Failure. Перед каждым Failure формируется участок постепенной деградации: температура, вибрация, влажность и энергопотребление увеличиваются, давление снижается. Кроме этих интервалов в данные добавлены точечные выбросы и кратковременные групповые аномалии. Эталонная разметка для сравнения методов объединяет сам статус Failure и предаварийный участок деградации.

Реалистичный датасет строится по той же модели, но охватывает весь 2025 год. В нем часть аварийных состояний размечена явно, а часть остается скрытой. Примерно 30 % отказов сохраняют статус Running, несмотря на деградацию сенсоров.

Пример структуры исходных .csv-файлов приведен на Рисунке 1.

timestamp	machine_id	machine_name	temperature	vibration	humidity	pressure	energy_consumption	machine_status
2025-01-01 00:00:00	1	Оборудование 1	60.75541022001150	4.995200319431920	41.99078059053790	100.92730672104400	198.57097955393400	Running
2025-01-01 00:01:00	1	Оборудование 1	60.97374955760350	4.9503669683031100	40.54566265265090	101.11893153444100	199.43092567484600	Running
2025-01-01 00:02:00	1	Оборудование 1	60.44381148180720	4.2614842319088	36.80437453469460	101.1137213380530	200.3349168330940	Running
2025-01-01 00:03:00	1	Оборудование 1	60.06812527991210	4.9819954183315400	42.64295932271630	100.54109190322500	194.88766065586800	Running
2025-01-01 00:04:00	1	Оборудование 1	60.09417266592130	5.022771387287400	36.326476923335200	101.78995408357900	210.39649139483900	Running

Рисунок 1 – Структура данных
Figure 1 – Data structure

До применения метода к набору со скрытыми событиями LSTM-автоэнкодер сравнивался с пятью базовыми способами обнаружения аномалий на эталонных данных. Для каждого оборудования группировались соседние аномальные точки и проверялось пересечение полученного интервала с эталонной разметкой Failure вместе с предаварийным окном.

Результаты приведены в Таблице 1. LSTM-автоэнкодер выделял групповые аномалии, и все найденные группы имели пересечение с эталонной разметкой; у остальных методов доля пересечений находилась в диапазоне от 0 до 0,56.

По этой метрике LSTM-автоэнкодер оказался наиболее стабильным. Найденные им интервалы во всех запусках пересекались с эталонной разметкой.

Таблица 1 – Сравнение методов обнаружения аномалий на эталонном наборе
Table 1 – Comparison of anomaly detection methods on a reference dataset

Метод	Групповые аномалии	Доля пересечений с эталоном	Время выполнения, с
Правило трёх сигм	0–31	0,00–0,43	~0
kNN	14–33	0,07–0,48	3,7–4,1
LOF	0–2	0	~5
ABOD	14–26	0,07–0,56	700–800
Isolation Forest	13–26	0,05–0,43	15–16
LSTM Autoencoder	3–6	1,00	660–785

На втором наборе анализ выполнялся уже без опоры на метку отказа. Найденный по реконструктивной ошибке интервал сопоставлялся с журналом, и при отсутствии Failure относился к неявной аномалии. Характерный фрагмент результата показан на Рисунке 2.

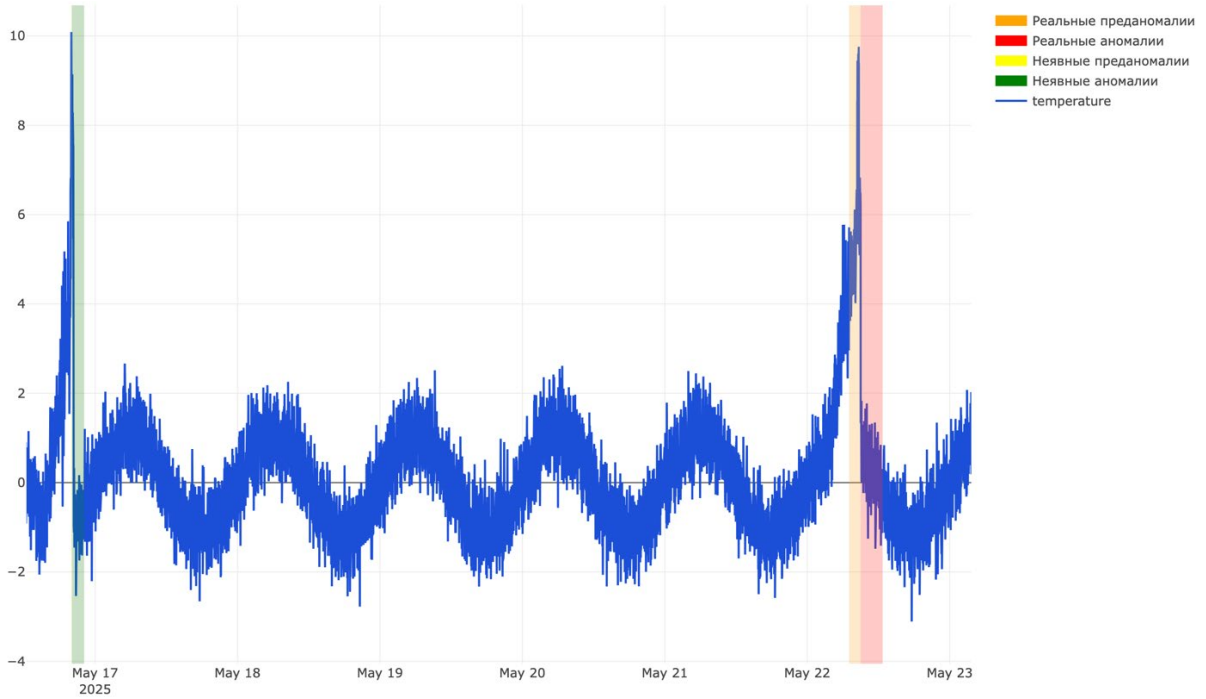


Рисунок 2 – Выявление неявных аномалий
Figure 2 – Detection of implicit anomalies

Заключение

В статье введено понятие неявной аномалии, формализована проблема пропущенных событий в условиях цензурированных данных, предложен метод детектирования неявных аномалий, который не требует размеченных данных, предложен критерий верификации неявных аномалий на основе плотности реконструктивных отклонений.

Дальнейшие исследования будут направлены на интеграцию с системами цифровых двойников.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Shcherbakov M.V., Safonova E.V., Shcherbakova N.L., Kravets A.G. Health Index Construction Method for Distributed Cyber-Physical Systems. In: *Frontiers of Industrial Cyber-Physics*. Cham: Springer; 2026. P. 71–89. https://doi.org/10.1007/978-3-032-02717-7_6
2. Safonova E., Kravets A., Shcherbakov M., Kizim A., Al-Gunaid M., Echin A. Industrial Environmental Impact Assessment Method Based on Detection of Complex Anomalies in Time Series. *Applied System Innovation*. 2024;7(5):89. https://doi.org/10.3390/asi7050089
3. Kleinbaum D.G., Klein M. *Survival Analysis: A Self-Learning Text*. New York: Springer; 2012. 700 p.
4. Константинов А.В., Уткин Л.В. Глубокий лес для анализа выживаемости в рамках многовариантного обучения. В сборнике: *XXII национальная конференция по искусственному интеллекту с международным участием (КИИ-2025): Том 3, 06–10 октября 2025 года, Санкт-Петербург, Россия.* Санкт-Петербург: Санкт-Петербургский Федеральный исследовательский центр РАН; 2025. С. 95–102.

5. Chandola V., Banerjee A., Kumar V. Anomaly Detection: A Survey. *ACM Computing Surveys*. 2009;41(3):15. https://doi.org/10.1145/1541880.1541882
6. Blázquez-García A., Conde A., Mori U., Lozano J.A. A Review on Outlier/Anomaly Detection in Time Series Data. *ACM Computing Surveys*. 2021;54(3):56. https://doi.org/10.1145/3444690
7. Zhou Ch., Paffenroth R.C. Anomaly Detection with Robust Deep Autoencoders. In: *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2017), 13–17 August 2017, Halifax, NS, Canada*. New York: ACM; 2017. P. 665–674. https://doi.org/10.1145/3097983.3098052
8. Zong B., Song Q., Min M.R., et al. Deep Autoencoding Gaussian Mixture Model for Unsupervised Anomaly Detection. In: *Proceedings of the 6th International Conference on Learning Representations (ICLR 2018), 30 April – 03 May 2018, Vancouver, BC, Canada*. 2018. URL: https://iclr.cc/virtual/2018/poster/126
9. Liu F.T., Ting K.M., Zhou Zh.-H. Isolation Forest. In: *2008 8th IEEE International Conference on Data Mining (ICDM 2008), 15–19 December 2008, Pisa, Italy*. IEEE; 2008. P. 413–422. https://doi.org/10.1109/ICDM.2008.17
10. Hundman K., Constantinou V., Laporte Ch., Colwell I., Soderstrom T. Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding. In: *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2018), 19–23 August 2018, London, UK*. New York: ACM; 2018. P. 387–395. https://doi.org/10.1145/3219819.3219845
11. Li D., Chen D., Jin B., Shi L., Goh J., Ng S.-K. MAD-GAN: Multivariate Anomaly Detection for Time Series Data with Generative Adversarial Networks. In: *Artificial Neural Networks and Machine Learning – ICANN 2019: Text and Time Series: 28th International Conference on Artificial Neural Networks: Part IV, 17–19 September 2019, Munich, Germany*. Cham: Springer; 2019. P. 703–716. https://doi.org/10.1007/978-3-030-30490-4_56
12. Ruff L., Görnitz N., Deecke L., et al. Deep One-Class Classification. In: *Proceedings of the 35th International Conference on Machine Learning (ICML 2018), 10–15 July 2018, Stockholm, Sweden*. PMLR; 2018. P. 4390–4399.
13. Xu J., Wu H., Wang J., Long M. *Anomaly Transformer: Time Series Anomaly Detection with Association Discrepancy.* arXiv. URL: https://arxiv.org/abs/2110.02642 [Accessed 16th August 2026].
14. Tuli Sh., Casale G., Jennings N.R. TranAD: Deep Transformer Networks for Anomaly Detection in Multivariate Time Series Data. *Proceedings of the VLDB Endowment*. 2022;15(6):1201–1214. https://doi.org/10.14778/3514061.3514067

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Сафонова Елена Владимировна, аспирант, преподаватель, Волгоградский государственный технический университет, Волгоград, Российская Федерация.
e-mail: safonova_h@mail.ru
ORCID: 0009-0006-3798-6506

Elena V. Safonova, Postgraduate, Lecturer, Volgograd State Technical University, Volgograd, the Russian Federation.

Алиева Наталья Денисовна, студент, Волгоградский государственный технический университет, Волгоград, Российская Федерация.
e-mail: alieva_nata@icloud.com
ORCID: 0009-0009-9115-5000

Natalia D. Alieva, Student, Volgograd State Technical University, Volgograd, the Russian Federation.

Щербаков Максим Владимирович, доктор технических наук, профессор РАН, заведующий кафедрой «Системы автоматизированного проектирования и поискового конструирования», Волгоградский государственный технический университет, Волгоград, Российская Федерация.
e-mail: maxim.shcherbakov@vstu.ru
ORCID: 0000-0001-7173-4499

Maxim V. Shcherbakov, Doctor of Engineering Sciences, Professor of the Russian Academy of Sciences, Head of the Department of Computer-aided Design and Search Engineering Systems, Volgograd State Technical University, Volgograd, the Russian Federation.

Статья поступила в редакцию 02.09.2026; одобрена после рецензирования 30.10.2026; принята к публикации 11.11.2026.

The article was submitted 02.09.2026; approved after reviewing 30.10.2026; accepted for publication 11.11.2026.