

ANOMALY DETECTION MODEL BASED ON UNSUPERVISED LEARNING FOR MULTIVARIATE INDUSTRIAL TIME SERIES

N. N. Limansky

Saint Petersburg State University of Economics, St. Petersburg, Russian Federation

This study focuses on developing an unsupervised anomaly detection model for multivariate time series generated by complex Cyber-Physical Systems (CPS) in shipbuilding and manufacturing enterprises, where strong inter-channel dependencies and regime drifts reduce the sensitivity of traditional Statistical Process Control (SPC) methods. The objective is to design a mathematically grounded model capable of detecting abnormal system behavior under varying operational conditions. The proposed approach includes: (1) representing system states through signature matrices that capture pairwise dependencies among process parameters; (2) reconstructing normal operational patterns using a Long Short-Term Memory (LSTM) neural network and its convolutional variant, Convolutional LSTM (ConvLSTM); (3) applying adaptive thresholds derived from the quantile rule and the Exponentially Weighted Moving Average (EWMA) method to account for process drift; and (4) localizing anomaly sources using residual maps and linking them to the control loop for interpretability. The model ensures scale invariance, sensitivity to cross-channel correlations, and robustness to regime shifts. Its practical application lies in real-time monitoring and early detection of deviations in ship power plants, cooling and fuel systems, and various stages of shipbuilding production, thereby reducing false alarms and providing interpretable diagnostics for operators.

Keywords: anomaly detection, process control, multivariate time series, feature matrix, neural model, encoder–decoder, adaptive threshold, residual error, quality control, feedback loop, cyber-physical system, unsupervised learning.

For citation:

Limansky, Nikolay N. “Anomaly detection model based on unsupervised learning for multivariate industrial time series.” *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admiral S. O. Makarova* 17.5 (2025): 768–778. DOI: 10.21821/2309-5180-2025-17-5-768-778.

УДК: 004.8

МОДЕЛЬ ОБНАРУЖЕНИЯ АНОМАЛИЙ НА ОСНОВЕ ОБУЧЕНИЯ БЕЗ УЧИТЕЛЯ ДЛЯ МНОГОМЕРНЫХ ВРЕМЕННЫХ РЯДОВ ТЕХНОЛОГИЧЕСКИХ ПАРАМЕТРОВ ПРОМЫШЛЕННЫХ ОБЪЕКТОВ

Н. Н. Лиманский

ФГБОУ ВО «Санкт-Петербургский государственный экономический университет»,
Санкт-Петербург, Российская Федерация

Темой работы является исследование процесса роста сложности киберфизических производственных систем (Cyber-Physical Systems) на судостроительных и судоремонтных заводах, который приводит к генерации многомерных временных рядов с сильными межканальными связями и «дрейфом» режимов, когда традиционные методы статистического контроля процессов (Statistical Process Control) теряют чувствительность. Целью исследования является разработка математически определенной модели обнаружения аномалий на основе обучения без учителя (Unsupervised Learning). Задачами исследования являются формализация представления состояния через сигнатурные матрицы, фиксирующие попарные зависимости между параметрами; реконструкция нормального поведения с помощью нейронной сети Long Short-Term Memory (сеть с долгой краткосрочной памятью) и ее сверточной модификации Convolutional Long Short-Term Memory; использование адаптивных порогов на основе квантильного правила и метода Exponentially Weighted Moving Average (экспоненциально взвешенное скользящее среднее) для учета дрейфа; локализация источников аномалий по остаточным картам и сопряжение с контуром управления. Модель обеспечивает масштабную инвариантность, чувствительность к межканальным

зависимостям и устойчивостью к режимным смещениям. Практическая значимость выполненного исследования заключается в мониторинге технологических процессов на этапах судостроительного производства, таких как сварка корпусов, сборка секций, испытания энергетических и вспомогательных систем, что снижает количество ложных тревог и обеспечивает оператору интерпретируемые причины срабатывания.

Ключевые слова: аномалия, управление процессом, временной ряд, матрица признаков, нейронная модель, кодировщик-декодировщик, адаптивный порог, остаточная ошибка, контроль качества, обратная связь, киберфизическая система, обучение без учителя.

Для цитирования:

Лиманский Н. Н. Модель обнаружения аномалий на основе обучения без учителя для многомерных временных рядов технологических параметров промышленных объектов / Н. Н. Лиманский // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2025. — Т. 17. — № 5. — С. 768–778. DOI: 10.21821/2309-5180-2025-17-5-768-778. — EDN WDIPTC.

Введение (Introduction)

Цифровизация производства и переход к киберфизическим системам *Cyber-Physical Systems* (CPS) сопровождаются ростом объема данных о технологических процессах в форме многомерных временных рядов, в которых параметры тесно взаимосвязаны и подвержены нелинейным изменениям. Поскольку для судостроительной отрасли исследование этих вопросов является особенно актуальным при изготовлении, производстве и испытаниях энергетических установок, систем охлаждения и топливоподачи, возникает необходимость в применении методов, устойчивых к дрейфу режимов и скрытым группам отклонений [1, 2].

Классические методы статистического контроля процессов *Statistical Process Control* (SPC), включая карты Шухарта и процедуры *Exponentially Weighted Moving Average* (EWMA), сохраняют ценность для фиксации крупных сдвигов, но малоэффективны при обнаружении слабых и постепенных аномалий. [3] Современные методы на основе нейронных сетей повышают чувствительность, однако часто ограничиваются анализом отдельных сигналов, неявно учитывают межканальные зависимости и, как правило, требуют размеченных выборок, которые в промышленности получить трудно [4].

Предлагаемый подход реализует совокупность принципиальных механизмов, которые в существующих решениях, как правило, применяются разрозненно:

- явное кодирование межканальных связей через многомасштабные сигнатурные матрицы;
- реконструкция нормального поведения с помощью ConvLSTM-автоэнкодера, учитывающего пространственно-временную структуру сигналов;
- адаптивная пороговая обработка (квантильная и EWMA), снижающая чувствительность к режимным дрейфам и случайным всплескам;
- интерфейс с контуром управления, позволяющий трансформировать диагностический сигнал в корректирующее воздействие [5].

Таким образом, в отличие от аналогов, модель не только фиксирует аномалии без учителя, но и объясняет их источник, сохраняя устойчивость к нестационарности и обеспечивая практическую интеграцию в системы управления.

Целью исследования является разработка и обоснование модели обнаружения аномалий на основе обучения без учителя, которая объединяет сигнатурные матрицы, ConvLSTM-автоэнкодер, адаптивные пороговые правила и сопряжение с управлением, обеспечивая интерпретируемость, масштабируемость и возможность внедрения в автоматические системы управления технологическими процессами судостроительных предприятий.

Методы и материалы (Methods and Materials)

Общая архитектура предложенного метода представлена на рис. 1. Схема отражает ключевые этапы обработки данных, анализа и принятия решений в задаче детектирования аномалий во временных рядах.




Рис. 1. Архитектура модели обнаружения аномалий

Рассмотрим кратко и последовательно все этапы.

Входные данные (скользящее окно, нормализация, сглаживание, PCA). Входные данные представляют собой многомерный временной ряд:

$$X(t) = \{x_1(t), x_2(t), \dots, x_d(t)\} \in R^d,$$

где $X(t)$ — вектор измерений в момент времени t (поток датчиков и при необходимости контекстные сигналы).

Предобработка данных

Для учета динамики ряд разбивается на перекрывающиеся окна длиной s со сдвигом h :

$$W_t = [X(t-s+1), \dots, X(t)] \in R^{(s \times n)}. \quad (1)$$

Параметры s и h согласуются с характерными временными масштабами процесса: большие s повышают устойчивость оценки межканальных связей ценой задержки; малые h увеличивают временное разрешение и вычислительную нагрузку.

Перед построением признаков выполняется поканальная нормализация (min-max или z-оценка) и при необходимости подавление высокочастотного шума экспоненциальным сглаживанием:

$$\overline{x_t^{(i)}} = \alpha x_t^{(i)} + (1 - \alpha) \overline{x_{t-1}^{(i)}}, \quad \alpha \in (0, 1). \quad (2)$$

Нормализация устраняет масштабные доминирования, а сглаживание формирует краткую «память» о последних наблюдениях и стабилизирует последующее обучение.

При очень больших n и выраженной мультиколлинеарности признаков целесообразно выполнить сжатие признакового пространства методом главных компонент (PCA). Предварительно данные по признакам центрируются, и при необходимости — стандартизируются.

Пусть $X \in R^{N \times n}$ — матрица наблюдений (по времени или по окнам), а X_c — центрированная версия X . Ковариационная матрица $S = \frac{1}{N-1} X_c^T X_c \in R^{n \times n}$ разлагается по собственным векторам: $Sw_i = \lambda_i w_i, \quad i = 1, \dots, n, \quad \lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$.

Собираем матрицу главных направлений $W_m = [w_1, \dots, w_m] \in R^{n \times m}$ и получаем сжатое представление в пространстве главных компонент $\tilde{X} = X_c W_m \in R^{N \times m}$. Число компонент m выбирают по доле объясненной дисперсии:

$$\rho(m) = \frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^n \lambda_i} \geq \eta, \quad \eta \in (0, 1)$$

либо по правилу «сломленной палки» (Broken Stick). Применение PCA уменьшает размер входа и ускоряет расчеты, сохраняя основную вариативность признаков.

Формирование признаков

Для каждого окна $W_t \in R^{s \times n}$ формируем сигнатурную матрицу (матрицу признаков) $\Phi_t \in R^{d \times d}$, где $d = n$ или $d = n + p$ при добавлении p контекстных переменных (уставки, возмущения, режимы).

Обозначим нормированные (и при необходимости — сглаженные) сигналы как $\widehat{x_t^{(i)}}$, а вектор окна для i -го канала: $\widehat{x_t^{(i)}}$, $\widehat{x_t^{(i)}} = (\widehat{x_{t-s+1}^{(i)}}, \dots, \widehat{x_t^{(i)}})^T \in R^s$. Тогда элементы Φ_t определяются косинусной мерой сходства между траекториями каналов на окне:

$$\Phi_{t,ij} = \frac{\widehat{x_t^{(i)}} \cdot \widehat{x_t^{(j)}}}{\|\widehat{x_t^{(i)}}\|_2 \|\widehat{x_t^{(j)}}\|_2}, \quad i, j = 1, \dots, d. \quad (3)$$

Свойства представления $\Phi_t = \Phi_t^T$, $\Phi_{t,ii} = 1$, $|\Phi_{t,ij}| \leq 1$. Такое представление делает явными межканальные связи, является масштабно инвариантным (нормирование устраняет влияние единиц измерения) и более устойчивым к одиночным выбросам, чем поканальный анализ уровней.

Для того, чтобы учитывать быстрые и медленные паттерны, формируется набор многомасштабных сигнатурных матриц $\{\Phi_t^{(l)}\}_{l=1}^L$, вычисленных на окнах разной длины $\{S_l\}_{l=1}^L$. Эти матрицы укладываются по «канальному» измерению в один многоканальный тензор — многомасштабное представление:

$$S_t = \text{stack}(\Phi_t^{(1)}, \dots, \Phi_t^{(L)}) \in R^{d \times d \times L},$$

которое повышает чувствительность к событиям различной длительности без изменения архитектуры модели: малые окна реагируют на кратковременные всплески, большие — на медленные дрейфы [6].

ConvLSTM-автоэнкодер

Последовательность входов $\{X_t\}$, где $X_t = \Phi_t$ при одном масштабе или $X_t = S_t$ при многомасштабном входе) обрабатывается сверточными LSTM-ячейками (ConvLSTM) — рис. 2,




Рис. 2. Структура ConvLSTM-ячейки
(https://www.researchgate.net/figure/Structure-of-a-ConvLSTM-memory-cell_fig2_359702698
(дата обращения 30.10.2025))

в которых матрицы «вход → состояние» и «состояние → состояние» заменены 2D-свертками по «пространству» сигнатуры. Динамика ячейки на шаге t задается формулами:

$$\begin{aligned} i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + b_i); \\ f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + b_f); \\ \tilde{C}_t &= \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c); \\ C_t &= f_t \odot C_{t-1} + i_t \odot \tilde{C}_t; \\ o_t &= \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + b_o); \\ H_t &= o_t \odot \tanh(C_t). \end{aligned} \quad (4)$$

где $*$ — 2D-свертка; \odot — поэлементное произведение; H_t — скрытое состояние; C_t — состояние ячейки.

Декодер восстанавливает $\hat{\Phi}_t$ (соответствующий канал/масштаб), стремясь к точной реконструкции нормальных паттернов [7].

Практические настройки. Ядра свертки 3×3 или 5×5 , паддинг *same*, 32–128 карт признаков на слой; пакетная нормализация (Batch Normalization) или нормализация по слоям (Layer Normalization) между ячейками; активации \tanh/σ как в формулах (4). Допустимы прямые соединения (Skip Connections) между симметричными блоками кодировщика и декодировщика [8].

Обучение и регуляризация (обучение без учителя). Модель обучается без учителя на «норме», минимизируя квадратичную ошибку реконструкции:

$$L_{MSE} = \sum_t \|\Phi_t - \hat{\Phi}_t\|_F^2. \quad (5)$$

На практике полезной является смешанная функция потерь с $L1$ -штрафом и слабой регуляризацией по полной вариации (TV), сглаживающей «зернистые» артефакты:

$$L = \sum_t \left(\|\Phi_t - \hat{\Phi}_t\|_F^2 + \lambda_1 \|\Phi_t - \hat{\Phi}_t\|_1 + \lambda_{TV} \text{TV}(\hat{\Phi}_t) \right),$$

$$\text{где } \text{TV}(\hat{\Phi}_t) = \sum_{i,j} \sqrt{(\nabla_x \hat{\Phi}_t)_{ij}^2 + (\nabla_y \hat{\Phi}_t)_{ij}^2} + \varepsilon.$$

Оптимизация: Adam/AdamW — ранняя остановка по валидационному окну; $L2$ — регуляризация весов; Dropout (дропаут) — параметр в сверточных блоках.

Временное внимание (Temporal Attention) для длинных последовательностей:

$$\alpha_t = \frac{\exp(q^\top h_t)}{\sum_\tau \exp(q^\top h_\tau)}, \quad \hat{H} = \sum_t \alpha_t h_t,$$

где $h_t = \text{vec}(H_t)$ — агрегированная проекция скрытого состояния; q — обучаемый вектор запроса.

Такой механизм повышает устойчивость к варьирующей длительности паттернов и позволяет фокусироваться на информативных интервалах.

Анализ ошибки

Скалярная ошибка окна вычисляется как норма Фробениуса разности исходной и восстановленной сигнатурных матриц по формуле

$$e_t = \|\Phi_t - \widehat{\Phi}_t\|_F. \quad (6)$$

Для операционной диагностики формируется тепловая карта вкладов:

$$\Delta_t = \left| \Phi_t - \widehat{\Phi}_t \right|,$$

где каждая ячейка $\Delta_{t,ij}$ отражает величину несогласованности между каналами i и j . Суммирование Δ_t по строкам / столбцам дает рейтинг каналов (датчиков), ответственных за тревогу; максимумы по подматрицам указывают подозрительные кластеры параметров.

Адаптивные пороги

Чтобы корректно работать в условиях дрейфа режимов, применяется адаптивная пороговая обработка.

Квантильный (непараметрический) порог:

$$\tau_t = \text{Quantile}_q(e_{t-w+1}, \dots, e_t), \quad (7)$$

не зависит от предположений о распределении ошибки и легко переносится между объектами.

Порог на основе экспоненциально взвешенного скользящего среднего (EWMA):

$$z_t = \lambda e_t + (1 - \lambda) z_{t-1}, \quad sd(z_t) \approx \sigma_e \sqrt{\frac{\lambda}{2 - \lambda}}, \quad (8)$$

где $\lambda \in [0,15;0,30]$ — коэффициент сглаживания; σ_e — стандартное отклонение ошибок реконструкции.

Сигнал тревоги формируется при $z_t > \mu_{z_t} + L \cdot sd(z_t)$, где L подбирают по целевой средней длине пробега (ARL).

Комбинированный критерий: тревога возникает, если одновременно выполняется $e_t > \tau_t$ и / или условие EWMA. Такая схема снижает количество ложных срабатываний от одиночных всплесков и повышает чувствительность к устойчивым смещениям.

Реакция: оповещение, корректирующее воздействие, игнорирование

Для связи с системой автоматического управления (АСУ) формируется вектор системной ошибки:

$$e^{(\text{sys})}(t) = r(t) - X(t),$$

где $r(t)$ — уставки (заданные значения параметров).

Управляющее воздействие вычисляется следующим образом:

$$U(t) = K e^{(\text{sys})}(t), \quad (9)$$

где K — матрица коэффициентов усиления, согласующаяся с политикой управления и требованиями устойчивости.

Такой интерфейс превращает диагностический сигнал в корректирующее действие: изменение уставок, перевод в безопасный режим, вызов обслуживающих процедур.

Вычислительная сложность и ресурсы

Построение сигнатурной матрицы Φ_t по (3) имеет вычислительную сложность $O(sd^2)$ на одно окно, где s — длина окна, d — число каналов.

Многомасштабная версия масштабируется линейно по числу шкал L . Один слой ConvLSTM обрабатывает последовательность длины T за $O(Td^2k^2c)$, где $k \times k$ — размер ядра, c — число карт признаков. Для больших d рекомендуется использовать PCA-сжатие и / или блочную обработку групп коррелированных каналов.

В онлайн-режиме конвейер работает потоково: нормализация и сглаживание $\rightarrow \Phi_t \rightarrow$ кодировщик-декодировщик $\rightarrow (e_t, z_t) \rightarrow$ пороговая обработка \rightarrow тревога и при необходимости управляющее воздействие $U(t)$.

Результаты (Results)

Свойства представления Φ_t . Представление окна процесса в виде сигнатурной матрицы Φ_t (см. формулу (3)) обладает двумя ключевыми свойствами, критичными для устойчивого обучения автоэнкодера. Во-первых, симметричность и нормировочная конструкция элементов $\Phi_{t,ij}$ гарантируют ограниченность $|\Phi_{t,ij}| \leq 1$, что снижает влияние масштабов отдельных каналов, препятствуя «взрыву» градиентов при обучении. Ограничение по модулю также означает, что реконструкционная ошибка в норме Фробениуса не может расти лишь из-за различий в единицах измерения. Во-вторых, многомасштабное расширение $\{\Phi_t^{(l)}\}_{l=1}^L$, где для разных l используются окна длины s_l , повышает чувствительность к событиям различной длительности: кратковременные всплески отражаются в «мелких» картах, медленные дрейфы — в «крупных». Это согласуется с результатами исследований, где сигнатурные матрицы подаются в кодировщик-декодировщик ConvLSTM с механизмами внимания: точность реконструкции нормальных паттернов возрастает, а локализация источников аномалий по остаточным картам улучшается и становится более интерпретируемой. Именно таким образом обосновывается архитектура MSCRED, где многомасштабные сигнатуры служат базой для учета межканальных связей и временной динамики [9, 10].

Дополнительный эффект дает косинусоподобная форма (3): если два канала изменяются пропорционально (например, из-за общего возмущения), то их нормированные траектории остаются согласованными и $\Phi_{t,ij} \approx 1$; если изменяется характер взаимосвязи, то это отражается сильнее, чем на отдельно взятом канале. Таким образом, автоэнкодер обучается реконструировать именно *структуру согласованности*, что согласуется с природой групповых аномалий в технологических процессах. Этот прием: явное кодирование межсенсорных взаимосвязей, системно обоснован в работах по многомерным временным рядам и остаточным сигнатурным матрицам.

Вычислительная сложность. Построение Φ_t по формуле (3) требует порядка $O(s^2)$ операций для одного окна: для d каналов усредняются $\frac{d(d-1)}{2}$ попарных произведений по s отсчетам. Нормировки по l_2 могут обновляться инкрементально. Эта стадия является вычислительно доминирующей на CPU при очень больших d .

Обработка ConvLSTM имеет сложность $O(Td^2k^2c)$, где T — длина последовательности, $k \times k$ — размер ядра свертки, c — число карт признаков. Память растет линейно по длине последовательности и числу слоев.

Для контроля квадратичного роста по d практически оправдано применение PCA-сжатия до $m \ll d$ информативных компонент, что подробно рассмотрено в работе [11]. Важно, что многомасштабный стек $\{\Phi_t^{(l)}\}_l$ увеличивает вычислительные затраты лишь линейно по числу шкал L . При этом рост затрат компенсируется выигрышем в устойчивости реконструкции и разрешающей способности диагностики [1].

Свойства адаптивного порога. В условиях слабой стационарности и медленных структурных дрейфов фиксированные пороги приводят либо к каскаду ложных тревог, либо к пропуску малых сдвигов.

Порог на основе EWMA (см. формулу (8)):

$$z_t = \lambda e_t + (1 - \lambda) z_{t-1},$$

агрегирует недавнюю историю ошибок реконструкции и обеспечивает чувствительность к небольшим (доли стандартного отклонения) смещениям. Классический анализ EWMA-карт показывает, что при $\lambda \in [0,15; 0,30]$ достигается компромисс между скоростью реакции и устойчивостью к шуму.

Пределные линии:

$$\mu_{z_t} \pm L \cdot sd(z_t),$$

настраиваются по целевой ARL (средней длине пробега), что формально связывает частоту ложных тревог и задержку обнаружения [12, 13]. Однако предположение о конкретной форме распределения ошибок e_t часто не выполняется. Поэтому непараметрический квантильный порог (7) оказывается более устойчивым к распределениям с тяжелыми хвостами и к смене режимов. Его эффективность была показана при мониторинге телеметрии космических аппаратов SMAP и MSL — применение динамического квантильного порогового правила позволило уменьшить частоту ложных срабатываний при сохранении чувствительности [14].

Согласно практическим рекомендациям следует использовать комбинацию процедур: квантильное правило, отражающее структуру хвоста при нестационарности, и EWMA, обеспечивающую раннюю реакцию на малые систематические смещения.

Локализация источника аномалии выполняется на основе тепловой карты $\Delta_t = |\Phi_t - \widehat{\Phi}_t|$, отражающей пространственное распределение остатка:

- большие значения $\Delta_{t,ij}$ указывают пары каналов с наибольшими нарушениями согласованности;
- суммирование по строкам / столбцам позволяет выявить «виновные» датчики;
- поиск связанных подматриц с повышенным остатком помогает обнаружить кластеры параметров и предполагаемые узлы причинно-следственных связей.

Такой метод диагностики, как анализ остаточных сигнатур межканальных связей, показал практическую ценность в архитектурах MSCRED: по Δ_t удастся локализовать неисправные подсистемы и формировать наглядные визуализации для инженеров-операторов [9].

Обсуждение (Discussion)

Связь с существующими подходами. Использование сверток в рекуррентных переходах является основной идеей ConvLSTM: заменив полносвязные матрицы «вход → состояние» и «состояние → состояние» на двумерные свертки, модель начинает учитывать локальную пространственную структуру входных данных и ее временную эволюцию. Эта концепция была системно обоснована и подтверждена в задаче прогноза осадков (nowcasting), где и входные, и выходные данные представляют собой пространственно-временные поля. Перенос данной идеи на индустриальные данные, в которых «пространством» выступают взаимосвязи между каналами (сигнатурные матрицы Φ_t), является естественным и эффективным.

Практическая реализация подхода заключается в подаче многомасштабных сигнатурных матриц в ConvLSTM-кодировщик–декодировщик. Такой метод был исследован в архитектуре MSCRED и близких системах, где были получены значимые улучшения как по точности обнаружения аномалий, так и по диагностике их первопричин [9, 10].

Пороговые методы и эксплуатационная устойчивость. С эксплуатационной точки зрения комбинация непараметрического квантильного порогового правила и EWMA-порогового значения позволяет учесть противоречивые требования:

- избегать избыточной чувствительности к единичным всплескам;
- фиксировать малые, но устойчивые сдвиги.

Порог на основе EWMA определяется рекурсией:

$$z_t = \lambda e_t + (1 - \lambda) z_{t-1},$$

где $\lambda \in [0,15; 0,30]$ выбирается как компромисс между скоростью реакции и устойчивостью к шуму.

Пороговые линии:

$$\mu_{z_t} \pm L \cdot sd(z_t),$$

настраиваются по целевой ARL (средней длине пробега), что позволяет формально увязать частоту ложных тревог с задержкой обнаружения [15, 16].

В то же время квантильная пороговка, вычисляемая по скользящему окну ошибок, является распределенно-независимой (форматно-агностичной) и устойчивой к нестационарным хвостам. В инженерных приложениях сочетание этих процедур показывает лучшие результаты: квантиль стабилизирует работу при смене режимов, а EWMA позволяет оперативно выявлять малые систематические смещения [14].

Таким образом, гибридный режим сочетает преимущества классических методов статистического контроля качества (SPC) и современных подходов мониторинга на основе глубокого обучения.

Ограничения и расширения. Основные ограничения связаны со следующими факторами: квадратичная вычислительная сложность по числу каналов d при построении Φ_i и обработке сверточных блоков. Это ограничение смягчается использованием PCA-сжатия, блочной обработки и инженерной оптимизации вычислений.

Необходимость онлайн-калибровки порогов при смене режимов. Комбинированная схема (квантиль + EWMA) частично решает проблему, однако в реальной эксплуатации полезно дополнение ее процедурными элементами: гистерезисом, подавлением дрейбзга, масками на сервисные события.

Существует риск переобучения механизмов внимания на редких паттернах, который можно минимизировать регуляризацией и контролем длины обучающих окон.

Перспективные направления развития включают:

- использование гибридных признаков (спектральные и вейвлет-подписи);
- применение графовых рекуррентных сетей для учета физической топологии взаимодействий;
- перенос обучения между схожими технологическими объектами;
- разработку мер доверия и методов объяснимости на основе декомпозиции вкладов Δ_i .

Эти направления соответствуют современным исследованиям глубоких методов обнаружения аномалий в многомерных временных рядах и систем с явным учетом межканальных взаимосвязей [17].

Выводы (Summary)

На основе полученных результатов исследования можно сделать следующие выводы:

1. В работе предложена модель обнаружения аномалий в многомерных временных рядах, основанная на обучении без учителя, ключевые особенности которой включают:
 - формализацию межканальных зависимостей через сигнатурные матрицы;
 - реконструкцию нормального поведения с помощью ConvLSTM-автоэнкодера;
 - адаптивные пороги с учетом дрейфа режимов;
 - локализацию источников отклонений и интеграцию с контуром управления.
2. Модель обеспечивает интерпретируемость результатов и устойчива к нестационарности, что делает ее применимой в судостроении для мониторинга и раннего предупреждения отклонений в энергетических установках и технологических линиях.
3. Практическая значимость модели заключается в снижении числа ложных тревог и повышении надежности диагностики при мониторинге судовых энергетических установок и технологических процессов судостроительного производства. Перспективы развития связаны с использованием спектральных и графовых признаков, онлайнового дообучения и расширения методов объяснимости, что обеспечит дальнейшее повышение эффективности цифровых решений в судостроительной отрасли.

СПИСОК ЛИТЕРАТУРЫ

1. Lee J. A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems / J. Lee, B. Bagheri, H.-A. Kao // Manufacturing Letters. — 2015. — Vol. 3. — Pp. 18–23. DOI: 10.1016/j.mfglet.2014.12.001.
2. Куприяновский В. П. Кибер-физические системы как основа цифровой экономики / В. П. Куприяновский, Д. Е. Намиот, С. А. Синягов // International Journal of Open Information Technologies. — 2016. — Т. 4. — № 2. — С. 18–25. — EDN VKCXLH.

3. *Ozbayoglu A. M.* Deep learning for financial applications: A survey / A. M. Ozbayoglu, M. U. Gudelek, O. B. Sezer // *Applied Soft Computing*. — 2020. — Vol. 93. — Pp. 106384. DOI: 10.1016/j.asoc.2020.106384.
4. Адлер Ю. П. Контрольные карты Шухарта в России и за рубежом. Часть 1 / Ю. П. Адлер, О. В. Максимова, В. Л. Шпер // *Стандарты и качество*. — 2011. — № 7. — С. 82–87. — EDN NXZTNV.
5. *Åström K. J.* Feedback Systems: An Introduction for Scientists and Engineers. / K. J. Åström, R. M. Murray. — Princeton: Princeton Univ. Press, 2008. — 408 p.
6. Журилова О. Е. Современные методы и задачи спектрального анализа сигналов: краткий обзор и сравнение / О. Е. Журилова, А. В. Башкиров, С. Ю. Белецкая [и др.] // *Вестник Воронежского государственного технического университета*. — 2019. — Т. 15. — № 2. — С. 128–131. DOI: 10.25987/VSTU.2019.15.2.016. — EDN HAUOVJ.
7. *Hochreiter S.* Long Short-Term Memory / S. Hochreiter, J. Schmidhuber // *Neural Computation*. — 1997. — Vol. 9. — Is. 8. — Pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
8. *SHI X.* Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting / X. SHI, Z. Chen, H. Wang, D-Y. Yeung, W-Wong, W-WOO // *Advances in Neural Information Processing Systems*. — 28 — Curran Associates, Inc., 2015.
9. *Zhang C.* A Deep Neural Network for Unsupervised Anomaly Detection and Diagnosis in Multivariate Time Series Data / C. Zhang, D. Song, Y. Chen, X. Feng, C. Lumezanu, W. Cheng, J. Ni, B. Zong, H. Chen, N. V. Chawla // *Proceedings of the AAAI Conference on Artificial Intelligence*. — 2019. — Vol. 33. — Is. 01. — Pp. 1409–1416. DOI: 10.1609/aaai.v33i01.33011409.
10. *Qingning L.* Multi-Scale Anomaly Detection for Time Series with Attention-based Recurrent Autoencoders / L. Qingning, L. Wenzhong, Z. Chuanze [и др.] // *Proceedings of Machine Learning Research* — 189 — PMLR, 2023. — С. 674–689.
11. *Jolliffe I. T.* Principal component analysis: a review and recent developments / I. T. Jolliffe, J. . Cadima // *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*. — 2016. — Vol. 374. — Is. 2065. — Pp. 20150202. DOI: 10.1098/rsta.2015.0202.
12. Намиот Д. Е. Мониторинг сдвига данных в моделях машинного обучения / Д. Е. Намиот, Е. А. Ильюшин // *International Journal of Open Information Technologies*. — 2022. — Т. 10. — № 12. — С. 84–93. — EDN NDOMRK.
13. Марчук В. И. Анализ методов адаптации порогового значения при обнаружении аномальных измерений / В. И. Марчук, К. Е. Румянцев // *Известия высших учебных заведений России. Радиоэлектроника*. — 2006. — № 1. — С. 29–34. — EDN THUIIR.
14. *Hundman K.* Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding / K. Hundman, V. Constantinou, C. Laporte, I. Colwell, T. Soderstrom // *KDD '18 — Association for Computing Machinery*, 2018. — С. 387–395. DOI: 10.1145/3219819.3219845.
15. *Lucas J. M.* Exponentially Weighted Moving Average Control Schemes: Properties and Enhancements / J. M. Lucas, M. S. Saccucci // *Technometrics*. — 1990. — Vol. 32. — Is. 1. — Pp. 1–12. DOI: 10.1080/00401706.1990.10484583.
16. NIST/SEMATECH e-Handbook of Statistical Methods [Электронный ресурс]. — Режим доступа: <https://www.itl.nist.gov/div898/handbook/> (дата обращения: 09.08.2025).
17. *Wang F.* A Survey of Deep Anomaly Detection in Multivariate Time Series: Taxonomy, Applications, and Directions / F. Wang, Y. Jiang, R. Zhang, A. Wei, J. Xie, X. Pang // *Sensors*. — 2025. — Vol. 25. — Is. 1. DOI: 10.3390/s25010190.

REFERENCES

1. Lee, J., B. Bagheri and H-A. Kao. “A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems.” *Manufacturing Letters* 3 (2015): 18–23. DOI: 10.1016/j.mfglet.2014.12.001.
2. Kupriyanovskiy, V. P., D. E. Namiot and S. A. Sinyagov. “Cyber-physical systems as a base for digital economy.” *International Journal of Open Information Technologies* 4.2 (2016): 18–25.
3. Ozbayoglu, A. M., M. U. Gudelek and O. B. Sezer. “Deep learning for financial applications: A survey.” *Applied Soft Computing* 93 (2020): 106384. DOI: 10.1016/j.asoc.2020.106384.
4. Adler, Yu. P., O. V. Maksimova and V. L. Shper. “Kontrol’nye karty Shukharta v Rossii i za rubezhom. Chast’ 1.” *Standards and Quality* 7 (2011): 82–87.

5. Åström K. J. and R. M. Murray. *Feedback Systems: An Introduction for Scientists and Engineers*. Princeton: Princeton Univ. Press, 2008: 408 p.
6. Zhurilova, O. E., A. V. Bashkirov et al. “Modern methods and problems of spectral analysis of signals: brief discussion and comparison.” *Bulletin of Voronezh State Technical University* 15.2 (2019): 128–131. DOI: 10.25987/VSTU.2019.15.2.016.
7. Hochreiter, S. and J. Schmidhuber. “Long Short-Term Memory.” *Neural Computation* 9.8 (1997): 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
8. SHI, X., W.-. WOO, et al. “Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting.” *Advances in Neural Information Processing Systems* — 28Curran Associates, Inc., 2015.
9. Zhang, C., N. V. Chawla, et al. “A Deep Neural Network for Unsupervised Anomaly Detection and Diagnosis in Multivariate Time Series Data.” *Proceedings of the AAAI Conference on Artificial Intelligence* 33.01 (2019): 1409–1416. DOI: 10.1609/aaai.v33i01.33011409.
10. Qingning, L., L. Sanglu, et al. “Multi-Scale Anomaly Detection for Time Series with Attention-based Recurrent Autoencoders.” *Proceedings of Machine Learning Research* — 189PMLR, 2023: 674–689.
11. Jolliffe, I. T. and J. . Cadima. “Principal component analysis: a review and recent developments.” *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 374.2065 (2016): 20150202. DOI: 10.1098/rsta.2015.0202.
12. Namiot, D. E. and E. A. Il'yushin. “Data shift monitoring in machine learning models.” *International Journal of Open Information Technologies* 10.12 (2022): 84–93.
13. Marchuk, V. I. and K. E. Rumyantsev. “Analysis of the adaptation methods of threshold value at detection of abnormal measurements.” *Journal of The Russian Universities. Radioelectronics* 1 (2006): 29–34.
14. Hundman, K., T. Soderstrom, et al. “Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding.” *KDD '18Association for Computing Machinery*, 2018: 387–395. DOI: 10.1145/3219819.3219845.
15. Lucas, J. M. and M. S. Saccucci. “Exponentially Weighted Moving Average Control Schemes: Properties and Enhancements.” *Technometrics* 32.1 (1990): 1–12. DOI: 10.1080/00401706.1990.10484583.
16. NIST/SEMATECH e-Handbook of Statistical Methods. Web. 09 Aug. 2025 <<https://www.itl.nist.gov/div898/handbook/>>.
17. Wang, F., X. Pang, et al. “A Survey of Deep Anomaly Detection in Multivariate Time Series: Taxonomy, Applications, and Directions.” *Sensors* 25.1 (2025). DOI: 10.3390/s25010190.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Лиманский Николай Николаевич — ассистент
ФГБОУ ВО «Санкт-Петербургский
государственный экономический университет»
191023, Российская Федерация, Санкт-Петербург,
наб. канала Грибоедова, 30–32
e-mail: info@sohoware.ru

INFORMATION ABOUT THE AUTHORS

Limanskiy, Nikolay N. — Assistant lecturer
Saint Petersburg State University of Economics
30–32 Griboedov Canal Emb.,
St. Petersburg, 191023,
Russian Federation
e-mail: info@sohoware.ru

*Статья поступила в редакцию: 21 августа 2025 г.
Received: Aug. 21, 2025.*