

УДК 004.85

Контрастивное самообучение в системах мониторинга транспорта: практический подход к ранней детекции аномалий

**Коньков Дмитрий
Александрович**

— аспирант кафедры «Информационные и вычислительные системы». Научные интересы: контрастивное обучение, самообучающиеся системы, обеспечение безопасности информационных систем. E-mail: dmitry.konkov@letka.space

**Божко Леся
Михайловна**

— доктор экон. наук, профессор кафедры «Информационные и вычислительные системы». Научные интересы: математическое моделирование, численные методы, комплексы программ, управление в организационных системах. E-mail: lemib@rambler.ru

Петербургский государственный университет путей сообщения Императора Александра I, Россия, 190031, Санкт-Петербург, Московский пр., 9

Для цитирования: Коньков Д. А., Божко Л. М. Контрастивное самообучение в системах мониторинга транспорта: практический подход к ранней детекции аномалий // Интеллектуальные технологии на транспорте. 2026. № 2 (46). С. 82–90. DOI: 10.20295/2413-2527-2026-246-82-90

Аннотация. Для выявления дефектов и предупреждения аварий в транспортных системах используются датчики, применяющие модели на основе классических конструкций или пороговых правил, что чревато ложными тревогами или запаздыванием. Модели контрастивного самообучения позволяют снять указанные недостатки, но требуют доработки под прикладные задачи. **Цель исследования:** предложить и описать практический подход к использованию методов контрастивного самообучения для задач раннего обнаружения аномалий в системах мониторинга транспорта. **Методы:** применены методы контрастивного обучения с функцией потерь InfoNCE, легковесные сверточные энкодеры (ID-CNN/ID-ResNet), вариационные автокодировщики (VAE) для реконструкционного контроля, механизмы внимания для оценки вкладов сенсоров, адаптивная калибровка порогов на основе экспоненциального скользящего среднего (ЕМА), кластеризация представлений для множественных нормальных режимов и сценарии тестирования на полуреальных данных. **Результаты:** выявлены особенности мультисенсорных временных рядов, описаны ограничения полевых устройств и определены пути уменьшения ложных срабатываний при ограниченной разметке. Предложены алгоритмические блоки для практического внедрения: аугментации временных рядов, адаптивная калибровка порогов, attention-механизмы для объяснимости и валидация на полуреальных данных. Разработан гибридный критерий аномальности контрастивной и реконструкционной оценке аномальности. **Практическая значимость:** внедрение контрастивного блока с адаптивной калибровкой обеспечивает снижение времени обнаружения аномалий и сокращение частоты ложных срабатываний по сравнению с базовыми VAE и пороговыми системами. **Обсуждение:** рекомендуется интеграция контрастивных модулей и адаптивной калибровки в существующие системы мониторинга транспорта с использованием трехуровневой системы тревог и объяснений по каналам.

Ключевые слова: контрастивное самообучение, ранняя детекция, мультисенсорный мониторинг, мониторинг транспорта, адаптивная калибровка

1.2.2 — математическое моделирование, численные методы и комплексы программ (технические науки)

Введение

Современные транспортные системы все активнее используют датчики для оперативного выявления дефектов и предупреждения аварий: акселерометры и микрофоны на рельсах, датчики вибрации и температуры на вагонах, датчики тока и GPS [1]. При этом на практике возникают проблемы нехватки размеченных данных, смены условий эксплуатации (погодные нагрузки, тип поезда, скорость) и ограниченных вычислительных ресурсов на краю сети [2]. Классические модели на основе реконструкции (АЕ, VAE [3]) или пороговых правил часто либо дают ложные тревоги, либо запаздывают [4]. Контрастивное самообучение [5], напротив, позволяет формировать более различимые признаки при минимальной разметке, но оно требует доработки под прикладные ограничения. В статье рассматривается один из возможных вариантов взаимодействия инструментов контрастивного самообучения для практических задач обнаружения аномалий на ранних стадиях развития в системах мониторинга на транспорте.

Основная часть

Математическая формализация задачи обнаружения аномалий в мультисенсорных временных рядах для контрастивного самообучения нейронной сети [5, 6] будет выглядеть следующим образом.

Пусть $X = \{x_1, \dots, x_n\}$, $x_i \in \mathbb{R}^{d \times T}$, где d — число сенсорных каналов, T — длина окна. Энкодер E переводит сигнал в представление $z = E(x) \in \mathbb{R}^m$. Функция аномальности $A(x)$ сравнивается с порогом τ : $A(x) \geq \tau \Rightarrow$ аномалия, $A(x) < \tau \Rightarrow$ норма.

Архитектура для практической задачи внедрения модели контрастивного самообучения представлена следующим образом.

1. Сбор и предобработка.

Скользкие окна длиной 1–10 с. Набор аугментаций [5], для каждой $\forall t \in T$: $\tilde{x} = x(t)$. Примеры аугментаций: $\tilde{x} = x + \varepsilon$, $\varepsilon \sim \mathcal{N}(0, \sigma^2 I)$; временной сдвиг: $\tilde{x}[t] = x[t + \delta]$, $\delta \in [-\Delta, \Delta]$; маскирование каналов [7]: $\tilde{x}_i = m_i x_i$.

2. Компактный энкодер + контекст (на краю).

Энкодер E (1D-CNN/1D-ResNet) дает $z = E(x) \in \mathbb{R}^m$.

Практический паттерн: отдельные CNN для каналов $z_i = \text{CNN}_i(x_i)$, $z_{\text{concat}} = [z_1, \dots, z_d]$.

Здесь x_i — сигнал одного сенсорного канала (например, датчика температуры номер i); CNN_i — отдельная сверточная сеть для этого канала; z_i — компактное представление (эмбединг) этого канала; $z_1, \dots, z_d$ — представления всех d каналов; $[\cdot]$ — операция конкатенации (склеивания векторов); z_{concat} — итоговый объединенный вектор всех каналов.

Контекстный модуль (LSTM/Transformer light) дает конечное z .

3. Контрастивный модуль для представлений.

Косинусное сходство [5]:

$$\text{sim}(z_i, z_j) = \frac{z_i^\top z_j}{\|z_i\| \|z_j\|}.$$

InfoNCE-потеря [5] для пары (позитив z^+ , негативы $\{i = 1 \wedge K\}$):

$$\mathcal{L}_{\text{InfoNCE}} = -\log \frac{\exp(\text{sim}(z, z^+) / \kappa)}{\exp(\text{sim}(z, z^+) / \kappa) + \sum_{i=1}^K \exp(\text{sim}(z, z_i^-) / \kappa)},$$

где κ — температурный параметр. Негативы хранятся в буфере B размера K (FIFO).

4. Простая генеративная проверка (VAE) и комбинированный критерий VAE [3] реконструирует $x^\wedge$.

MSE-реконструкция:

$$\text{MSE}(x, \hat{x}) = \frac{1}{dT} \sum_{i=1}^d \sum_{t=1}^T (x_{i,t} - \hat{x}_{i,t}).$$

KL-дивергенция для нормального апостериорного $N(\mu, \text{diag}(\sigma^2))$:

$$\mathcal{L}_{\text{KL}} = \frac{1}{2} \sum_{j=1}^m (\mu_j^2 + \sigma_j^2 - \log \sigma_j^2 - 1).$$

Полная VAE-потеря [3, 7]:

$$\mathcal{L}_{\text{VAE}} = \text{MSE}(x, \hat{x}) + \beta \mathcal{L}_{\text{KL}},$$

где β — коэффициент регуляризации. Формулировка с весом β при KL-члене соответствует β -VAE; при $\beta = 1$ она совпадает с классическим VAE из [2].

Контрастивная оценка аномальности и реконструкционная оценка аномальности определяются как

$$S_{\text{contr}}(x) = 1 - \max_i \text{sim}(E(x), c_i),$$

$$S_{\text{recon}}(x) = \text{MSE}(x, \hat{x}).$$

Здесь контрастивная оценка аномальности должна расти при удалении представления от нормального поведения. Поэтому в качестве опорного множества берутся прототипы нормы (центроиды нормальных кластеров $\{c_i\}$, см. п. 6), а не буфер негативов: $S_{\text{contr}}(x) = 1 - \max_i \text{sim}(E(x), c_i)$. Для нормального объекта $\text{sim} \rightarrow 1$ и $S_{\text{contr}} \rightarrow 0$, для аномального — $S_{\text{contr}} \rightarrow 1$, что согласуется с InfoNCE и решающим правилом $A(x) \geq \tau$. Перед взвешиванием оценки аномальности S_{contr} и S_{recon} нормируются (например, робастной стандартизацией по нормальной выборке), чтобы коэффициент α имел смысл сопоставимого веса; значение α подбирается по валидации и проверяется ablation-сравнением (проверка вклада компонентов путем их поочередного отключения) с $\alpha = 0$ (только VAE) и $\alpha = 1$ (только контраст).

Комбинированный критерий [3, 5]:

$$A(x) = \alpha S_{\text{contr}}(x) + (1 - \alpha) S_{\text{recon}}(x), \alpha \in [0, 1].$$

Решение о тревоге: $A(x) \geq \tau$.

5. Attention для объяснимости.

Для каналов $x = [x_1, \dots, x_d]$ вычисляем скрытые представления h_i и attention-веса

$$a_i = \frac{\exp(Wh_i + b)}{\sum_{j=1}^d \exp(Wh_j + b)}.$$

Вклад i -го канала в общую аномальность: $C_i = a_i \times A(x)$.

Веса внимания интерпретируются как индикатор относительной значимости канала, а не как строгая каузальная мера вклада; для эксплуатации они служат подсказкой оператору о наиболее «подозрительном» канале.

6. Адаптация и калибровка на месте.

Онлайн-оценка статистик с ЕМА [10, 11]:

$$\mu_t = \gamma \mu_{t-1} + (1 - \gamma) A(x_t),$$

$$\nu_t = \gamma \nu_{t-1} + (1 - \gamma) (A(x_t) - \mu_t)^2,$$

$$\tau_t = \mu_t + \lambda \sqrt{\nu_t},$$

где $\gamma \in (0, 1)$ (например, 0,9–0,99);

λ — множитель для контроля FPR (обычно 2–3).

При множественности нормальных режимов используется кластеризация представлений [7, 8] с центроидами c_i и $d(E(x_t), c_i)$ и статистиками (μ_i, ν_i) , где ν_i — ЕМА-дисперсия оценки аномальности в i -м режиме. Для нового окна выбирается ближайший центроид $j = \text{argmin}_i d(E(x_t), c_i)$, и порог берется по его статистикам: $\tau_t = \mu_j + \lambda \sqrt{\nu_j}$. Тем самым обозначения согласованы с обычным режимом — всюду используется дисперсия ν и $\sqrt{\nu}$.

7. Тестирование и валидация в полевых условиях.

Рекомендуемые сценарии: синтетические инъекции дефектов, полуреальные тесты (пилоты на 1–2 состава/участка).

8. Метрики.

Стандартные метрики [9] оценивают качество классификации:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad \text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}},$$

$$\text{F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}.$$

Precision (точность) показывает, какая доля от всех тревог модели реально являлась аномалией (насколько можно доверять срабатыванию), **Recall** (полнота) — какую долю реальных аномалий модель обнаружила (ничего не пропустила), а **F1** объединяет их в одно число через гармоническое среднее, штрафую за сильный перекося в любую сторону.

TTD (Time to Detect) измеряет задержку между реальным началом аномалии и моментом ее обнаружения моделью: чем меньше, тем быстрее можно отреагировать.

FPR (False Positive Rate) нормирует количество ложных срабатываний на длину маршрута, позволяя корректно сравнивать системы на маршрутах разной протяженности: чем ниже значение, тем надежнее система в эксплуатации.

9. Примеры ожидаемой эффективности и пример расчета экономии.

На референсных сценариях внедрение контрастивного блока с адаптивной калибровкой обычно дает снижение TTD на 30–60% и снижение FPR на 25–50% по сравнению с простыми VAE/

пороговыми системами (при корректной калибровке). Приводимые значения являются прогнозными оценками на основе референсных диапазонов и подлежат подтверждению в полевых испытаниях. Экономическая оценка перехода от базового метода base к новому new:

$$E = C_{FP} \times (FPR_{base} - FPR_{new}) \times D + C_{delay} \times (TTD_{base} - TTD_{new}) \times N, \quad (1)$$

где C_{FP} — стоимость одной ложной проверки;
 C_{delay} — стоимость задержки на единицу времени;




Рисунок. Блок-схема практической системы мониторинга
 (сбор → энкодер → контекст → contrastive + VAE → пороговая логика → объяснение)

D — длина участка, км;

N — число дефектов за период.

Пример подстановки: при $FPR_{base} = 0,18/\text{км}$, $FPR_{new} = 0,09/\text{км}$, $D = 100$ км, $C_{FP} = 20\,000$ руб. получаем компоненту экономии по FP: $E_{FP} = 20\,000 \times (0,18 - 0,09) \times 100 = 180\,000$ руб.

Для интеграции в эксплуатацию рекомендует-ся [10, 11]:

- собирать при выездах технических бригад в течение нескольких часов (1–2) данные в штатных режимах работы;
- логировать attention-объяснения в отчетах;
- централизованно провести предобучение и локальную тонкую настройку на узлах;
- построить интерфейс с тремя уровнями тревоги и объяснением по каналам.

Практическая реализация системы мониторинга требует интеграции нескольких компонентов в единый конвейер обработки данных. Архитектура должна обеспечивать как качество детекции, так и возможность развертывания на устройствах с ограниченными ресурсами. Предлагаемая архитектура может быть представлена в виде последовательности функциональных блоков, как показано на рисунке.

На рисунке представлена последовательность обработки данных в предлагаемой системе. Мультисенсорные данные (вибрация, температура, ток, GPS) [1] поступают с транспортного средства и сегментируются скользящими окнами (блок «Сбор и предобработка»). Каждое окно подвергается аугментации (шум, сдвиг, маскирование каналов) для формирования позитивных пар. Легковесный энкодер (1D-CNN/ResNet) извлекает локальные признаки по каналам, которые объединяются и передаются в контекстный модуль (LSTM/Transformer с пониженной сложностью) [12, 13], формирующий финальное представление z .

Далее z направляется в два параллельных блока: контрастный модуль (InfoNCE-потеря [5] с буфером негативных примеров) для обучения различимых представлений и VAE [3] для реконструкционной проверки. Контрастная оценка аномальности S_{contr} и реконструкционная оценка аномальности S_{recon} взвешенно комбинируются

в финальный критерий аномальности $A(x)$. Пороговая логика (с адаптивной калибровкой через ЕМА) принимает решение о тревоге. Attention-механизм вычисляет вклады каждого сенсора в общую аномальность и формирует объяснения для оператора (какой канал вызвал тревогу и насколько). Вся схема рассчитана на развертывание на краевых устройствах с ограниченными ресурсами (отсюда легковесные архитектуры и онлайн-калибровка).

Анализ методов обнаружения аномалий с учетом специфики транспортной сферы, на основании логических и математических правил постановки задачи, а также выработанных выше метрик оценки позволил свести результаты такого анализа в единую таблицу.

Из таблицы можно сформулировать ряд ключевых выводов:

1. Пороговые правила простые, хорошо объяснимые, но требуют много ручной настройки и дают много ложных срабатываний.
2. VAE и LSTM Autoencoder улучшают показатели, но страдают от проблем с объяснимостью (особенно LSTM).
3. Изолированный лес не требует меток, но имеет посредственные показатели по TTD и FPR.
4. Контрастивное обучение значительно улучшает TTD и FPR с хорошей объяснимостью.
5. Гибридный подход (предлагаемый авторами) сочетает преимущества контрастивного обучения и VAE, достигая наилучших показателей по TTD и FPR при высокой объяснимости.

Таблица ниже наглядно демонстрирует превосходство предлагаемого гибридного подхода над существующими методами по ключевым метрикам производительности. Приведенные в таблице значения являются ориентировочными (референсными) диапазонами и требуют подтверждения в полевых испытаниях; в частности, преимущество гибрида над отдельными компонентами (только VAE, только контраст) должно быть подтверждено ablation-экспериментом.

Примеры расчета ожидаемой эффективности

Экономическая оценка внедрения проводилась на основе формулы (1).

Сравнение методов обнаружения аномалий в транспортном мониторинге

Метод	Основа	Требуемые метки, %	TTD, с	FPR, 1/км	Объяснимость
Пороговые правила	Ручные эксперты	> 50	180–300	0,15–0,25	Отлично
Классический VAE	Реконструкция	< 5	120–240	0,12–0,18	Средняя
LSTM Autoencoder	Временной контекст	< 5	90–180	0,10–0,15	Низкая
USAD	Adversarial + реконструкция	0	90–180	0,10–0,14	Низкая
Изолированный лес	Аномалия в пространстве	0	120–180	0,14–0,20	Средняя
Контрастивное обучение	Различимые представления	1–5	60–120	0,08–0,10	Высокая (attention)
Гибридный подход	Контрастив + VAE	1–5	48–120	0,08–0,09	Отлично

Пояснения к таблице:

- метод — названия различных подходов к обнаружению аномалий;
- основа — краткое описание принципа работы метода;
- требуемые метки — количество размеченных данных, необходимых для обучения;
- TTD — время до обнаружения аномалии в секундах (меньше = лучше);
- FPR — частота ложных срабатываний на километр пути (меньше = лучше);
- объяснимость — насколько понятны и интерпретируемы результаты.

Пример 1 (компонента ложных срабатываний).

При $FPR_{base} = 0,18/\text{км}$, $FPR_{new} = 0,09/\text{км}$, $D = 100$ км, $C_{FP} = 20\,000$ руб. экономия по компоненте ложных проверок составляет $E_{FP} = 20\,000 \times (0,18 - 0,09) \times 100 = 180\,000$ (руб.).

При $FPR_{base} = 0,18/\text{км}$, $FPR_{new} = 0,09/\text{км}$, $D = 100$ км, $C_{FP} = 20\,000$ руб. экономия по компоненте ложных проверок составляет $E_{FP} = 20\,000 \times (0,18 - 0,09) \times 100 = 180\,000$ (руб.).

Пример 2 (компонента времени обнаружения).

При $TTD_{base} = 180$ с, $TTD_{new} = 90$ с, $N = 50$ дефектов за период, $C_{delay} \approx 83,33$ руб./с экономия по компоненте сокращения времени составляет $E_{TTD} \approx 83,33 \times (180 - 90) \times 50 \approx 375\,000$ (руб.).

Суммарная ожидаемая экономия для данного сценария: $E_{total} = 180\,000 + 375\,000 = 555\,000$ (руб.) за период наблюдения. В качестве base здесь взяты значения порогового/VAE-метода по верхней границе таблицы; при выборе другого базового метода значения изменятся. Сдвиг FPR $0,18 \rightarrow 0,09$ соответствует диапазону снижения, указанному в п. 9.

Заключение

В результате предложенный гибридный подход, основанный на комбинации контрастивного самообучения и вспомогательного модуля реконструкции (VAE), а также дополненный attention-механизмом и адаптивной калибровкой, нацелен на снижение числа ложных срабатываний и задержек при детекции. Согласно сравнительному анализу (см. таблицу) и расчетам на референсных сценариях, ожидается снижение времени до обнаружения аномалии (TTD) и доли ложных тревог (FPR) относительно базовых методов, что создает основу для прямого экономического эффекта; количественное подтверждение требует полевых испытаний.

Полученные данные позволяют сделать вывод, что для современных систем мониторинга транспорта [1, 10] на первый план выходит не сложность самой модели, а задачи ее грамотной интеграции, полевой валидации и поддержки полного жизненного цикла. Перспективными направлениями для дальнейшей работы

становятся поиск путей оптимизации архитектуры для устройств с критически малым объемом ресурсов, а также разработка методов адаптации модели к новым типам подвижного состава в режиме онлайн, без необходимости полного переобучения.

СПИСОК ИСТОЧНИКОВ

1. Vehicle-as-a-Sensor Approach for Urban Track Anomaly Detection / V. Sruc [et al.] // *Sensors*. 2025. Vol. 25, iss. 21. Art. 6679. 24 p. DOI: 10.3390/s25216679
2. Thill M., Konen W., Bäck T. Online Anomaly Detection on the Webscope S5 Dataset: A Comparative Study // *Proceedings of the 2017 IEEE Workshop on Evolving and Adaptive Intelligent Systems (EAIS 2017)* (Ljubljana, Slovenia, 31 May — 2 June 2017). Institute of Electrical and Electronics Engineers, 2017. 8 p. DOI: 10.1109/EAIS.2017.7954844
3. Kingma D. P., Welling M. Auto-Encoding Variational Bayes // *Proceedings of the Second International Conference on Learning Representations (ICLR 2014)* (Banff, Canada, 14–16 April 2014). 14 p. DOI: 10.48550/arXiv.1312.6114
4. Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding / K. Hundman [et al.] // *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '18)* (London, United Kingdom, 19–23 August 2018). New York: Association for Computing Machinery, 2018. Pp. 387–395. DOI: 10.1145/3219819.3219845
5. A Simple Framework for Contrastive Learning of Visual Representations / T. Chen [et al.] // *Proceedings of the 37th International Conference on Machine Learning (ICML 2020)* (Virtual Event, 13–18 July 2020). *Proceedings of Machine Learning Research*. 2020. Vol. 119. Pp. 1597–1607.
6. USAD: Unsupervised Anomaly Detection on Multivariate Time Series / J. Audibert [et al.] // *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'20)*, (Virtual Event, 6–10 July 2020). New York: Association for Computing Machinery, 2020. Pp. 3395–3404. DOI: 10.1145/3394486.3403392
7. Deep Autoencoding Gaussian Mixture Model for Unsupervised Anomaly Detection / B. Zong [et al.] // *Proceedings of the Sixth International Conference on Learning Representations (ICLR 2018)* (Vancouver, Canada, 30 April — 3 May 2018). 19 p. URL: <http://openreview.net/forum?id=BJJLHbb0-> (дата обращения: 09.05.2026).
8. Deng A., Hooi B. Graph Neural Network-Based Anomaly Detection in Multivariate Time Series // *Proceedings of the 35th Conference on Artificial Intelligence (AAAI 2021)* (Virtual Event, 2–9 February 2021). *Proceedings of the AAAI Conference on Artificial Intelligence*. 2021. Vol. 35, no. 5. Pp. 4027–4035. DOI: 10.1609/aaai.v35i5.16523
9. On the Evaluation of Unsupervised Outlier Detection: Measures, Datasets, and an Empirical Study / G.O. Campos [et al.] // *Data Mining and Knowledge Discovery*. 2016. Vol. 30, iss. 4. Pp. 891–927. DOI: 10.1007/s10618-015-0444-8
10. Federated Learning: Challenges, Methods, and Future Directions / T. Li [et al.] // *IEEE Signal Processing Magazine*. 2020. Vol. 37, no. 3. Pp. 50–60. DOI: 10.1109/MSP.2020.2975749
11. Schneider J. Wenig P., Papenbrock T. Distributed Detection of Sequential Anomalies in Univariate Time Series // *The International Journal on Very Large Data Bases*. 2021. Vol. 30, iss. 4. Pp. 579–602. DOI: 10.1007/s00778-021-00657-6
12. Long Short Term Memory Networks for Anomaly Detection in Time Series / P. Malhotra [et al.] // *Proceedings of the 23rd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN 2015)* (Bruges, Belgium, 22–24 April 2015). i6doc.com Publishing, 2015. Pp. 89–94.
13. Robust Anomaly Detection for Multivariate Time Series Through Stochastic Recurrent Neural Network / Y. Su [et al.] // *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '19)* (Anchorage, AK, USA, 4–8 August 2019). New York: Association for Computing Machinery, 2019. Pp. 2828–2837. DOI: 10.1145/3292500.3330672

Дата поступления: 24.05.2026

Решение о публикации: 26.05.2026

Contrastive Self-Supervised Learning in Transportation Monitoring Systems: A Practical Approach to Early Anomaly Detection

Dmitry A. Konkov

— Postgraduate Student of the “Information and Computing Systems” Department. Research interests: contrastive learning, self-supervised systems, information-security assurance for information systems. E-mail: dmitry.konkov@letka.space

Lesya M. Bozhko

— Dr. Sci. in Economics, Professor of the “Information and Computing Systems” Department. Research interests: mathematical modeling, numerical methods, program complexes, management in organizational systems. E-mail: lemib@rambler.ru

Emperor Alexander I St. Petersburg State Transport University, 9 Moskovsky ave., Saint Petersburg, 190031, Russia

For citation: Konkov D. A., Bozhko L. M. Contrastive Self-Supervised Learning in Transportation Monitoring Systems: A Practical Approach to Early Anomaly Detection, *Intellectual Technologies on Transport*, 2026, no. 2 (46), pp. 82–90. DOI: 10.20295/2413-2527-2026-246-82-90 (In Russian)

Abstract. *To detect defects and prevent accidents in transport systems, sensors are used that use models based on classical designs or threshold rules, which is fraught with false alarms or delays. **Purpose:** to propose and describe a practical approach to the use of contrastive self-supervised learning methods for early detection of anomalies in transport monitoring systems. **Methods:** contrastive learning methods with the InfoNCE loss function, lightweight convolutional encoders (1D-CNN/1D-ResNet), variational autoencoders (VAE) for reconstruction control, attention mechanisms for assessing sensor contributions, adaptive calibration of thresholds based on the exponential moving average (EMA), representation clustering for multiple normal modes, and testing scenarios on semi-real data are applied. **Results:** features of multisensory time series have been identified, limitations of field devices have been described, and ways to reduce false positives with limited markup have been identified. Algorithmic blocks for practical implementation are proposed: time series augmentation, adaptive threshold calibration, attention mechanisms for explainability and validation on semi-real data. A hybrid anomaly criterion based on contrastive and reconstruction scores has been developed. **Practical significance:** the introduction of a contrast unit with adaptive calibration provides a decrease in the time for detecting anomalies and a decrease in the frequency of false positives compared to basic VAE and threshold systems. **Discussion:** integration of contrast modules and adaptive calibration into existing transport monitoring systems using a three-level alarm system with per-channel explanation.*

Keywords: *contrastive self-supervised learning, early detection, multi-sensor monitoring, transport monitoring, adaptive calibration*

REFERENCES

1. Sruk V., et al. Vehicle-as-a-Sensor Approach for Urban Track Anomaly Detection, *Sensors*, 2025, vol. 25, iss. 21, art. no. 6679, 24 p. DOI: 10.3390/s25216679
2. Thill M., Konen W., Bäck T. Online Anomaly Detection on the Webscope S5 Dataset: A Comparative Study, *Proceedings of the 2017 IEEE Workshop on Evolving and Adaptive Intelligent Systems (EAIS 2017)*, Ljubljana, Slovenia, May 31 — June 02, 2017. Institute of Electrical and Electronics Engineers, 2017, 8 p. DOI: 10.1109/EAIS.2017.7954844
3. Kingma D. P., Welling M. Auto-Encoding Variational Bayes, *Proceedings of the Second International Conference on Learning Representations (ICLR 2014)*, Banff, Canada, April 14–16, 2014, 14 p. DOI: 10.48550/arXiv.1312.6114

4. Hundman K., et al. Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding, *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '18)*, London, United Kingdom, August 19–23, 2018. New York, Association for Computing Machinery, 2018, pp. 387–395. DOI: 10.1145/3219819.3219845
5. Chen T., et al. A Simple Framework for Contrastive Learning of Visual Representations, *Proceedings of the 37th International Conference on Machine Learning (ICML 2020)*, Virtual Event, July 13–18, 2020. *Proceedings of Machine Learning Research*, 2020, vol. 119, pp. 1597–1607.
6. Audibert J., et al. USAD: Unsupervised Anomaly Detection on Multivariate Time Series, *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '20)*, Virtual Event, July 06–10, 2020. New York, Association for Computing Machinery, 2020, pp. 3395–3404. DOI: 10.1145/3394486.3403392
7. Zong B., et al. Deep Autoencoding Gaussian Mixture Model for Unsupervised Anomaly Detection, *Proceedings of the Sixth International Conference on Learning Representations (ICLR 2018)*, Vancouver, Canada, April 30 – May 03, 2018, 19 p. Available at: <http://openreview.net/forum?id=BJJLHbb0-> (accessed: May 09, 2026).
8. Deng A., Hooi B. Graph Neural Network-Based Anomaly Detection in Multivariate Time Series, *Proceedings of the 35th Conference on Artificial Intelligence (AAAI 2021)*, Virtual Event, February 02–09, 2021. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, vol. 35, no. 5, pp. 4027–4035. DOI: 10.1609/aaai.v35i5.16523
9. Campos G. O., et al. On the Evaluation of Unsupervised Outlier Detection: Measures, Datasets, and an Empirical Study, *Data Mining and Knowledge Discovery*, 2016, vol. 30, iss. 4, pp. 891–927. DOI: 10.1007/s10618-015-0444-8
10. Li T., et al. Federated Learning: Challenges, Methods, and Future Directions, *IEEE Signal Processing Magazine*, 2020, vol. 37, no. 3, pp. 50–60. DOI: 10.1109/MSP.2020.2975749
11. Schneider J. Wenig P., Papenbrock T. Distributed Detection of Sequential Anomalies in Univariate Time Series, *The International Journal on Very Large Data Bases*, 2021, vol. 30, iss. 4, pp. 579–602. DOI: 10.1007/s00778-021-00657-6
12. Malhotra P., et al. Long Short Term Memory Networks for Anomaly Detection in Time Series, *Proceedings of the 23rd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN 2015)*, Bruges, Belgium, April 22–24, 2015. i6doc.com Publishing, 2015, pp. 89–94.
13. Su Y., et al. Robust Anomaly Detection for Multivariate Time Series Through Stochastic Recurrent Neural Network, *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '19)*, Anchorage, AK, USA, August 04–08, 2019. New York, Association for Computing Machinery, 2019, pp. 2828–2837. DOI: 10.1145/3292500.3330672

Received: May 24, 2026

Accepted: May 26, 2026