

УДК 004.89

ПРИМЕНЕНИЕ АВТОЭНКODЕРОВ ДЛЯ ВЫЯВЛЕНИЯ АНОМАЛИЙ ВО ВРЕМЕННЫХ РЯДАХ

Антонов А.С., Старший оператор научной роты, III курс
Военная академия связи имени Маршала Советского Союза С. М. Буденного,
г. Санкт-Петербург

Автоэнкодеры являются мощным инструментом машинного обучения, который может использоваться для анализа временных рядов и обнаружения аномалий в них. Временные ряды широко применяются в различных областях, таких как финансы, производство, здравоохранение и многое другое. Однако, обнаружение аномалий в таких данных может быть сложной задачей из-за их динамичности и изменчивости. Давайте рассмотрим, как автоэнкодеры могут быть применены для выявления аномалий во временных рядах [1-5].

Автоэнкодеры — это нейронные сети, которые обучаются реконструировать входные данные на их выходе. Они состоят из двух основных частей: кодировщика (encoder), который сжимает входные данные в скрытое представление, и декодировщика (decoder), который восстанавливает входные данные из скрытого представления. В процессе обучения автоэнкодеры стремятся минимизировать ошибку реконструкции, что позволяет им извлекать наиболее информативные признаки из данных.

Применение автоэнкодеров для анализа временных рядов и выявления аномалий основано на том, что аномалии часто проявляются в форме неожиданных и необычных паттернов в данных. Основная идея заключается в том, что автоэнкодеры, обученные на нормальных данных, будут плохо справляться с реконструкцией аномальных данных из скрытого представления.

Процесс обнаружения аномалий с использованием автоэнкодеров обычно включает следующие шаги: [6-8]

- Обучение автоэнкодера. Автоэнкодер обучается на нормальных временных рядах без аномалий.
- Определение порогового значения. После обучения автоэнкодера определяется пороговое значение для ошибки реконструкции. Это может быть сделано на основе статистических методов или экспертного опыта.
- Выявление аномалий. Входные временные ряды подаются на вход автоэнкодеру, и вычисляется ошибка реконструкции для каждого примера. Если ошибка превышает установленный порог, пример считается аномальным.

Преимущества использования автоэнкодеров для выявления аномалий во временных рядах:

- Способность к извлечению сложных зависимостей: Автоэнкодеры способны автоматически извлекать информативные признаки из временных рядов, что позволяет им обнаруживать разнообразные типы аномалий.
- Адаптивность к различным типам данных: Автоэнкодеры могут быть применены к различным типам временных рядов без необходимости вручную настраивать модель для каждого конкретного случая.
- Эффективность: Автоэнкодеры могут быть обучены на больших объемах данных и обрабатывать их быстро, что делает их эффективным инструментом для обнаружения аномалий в реальном времени.

Заключение. Использование автоэнкодеров для выявления аномалий во временных рядах представляет собой мощный и гибкий подход, который может быть применен в различных областях, таких как финансы, производство, здравоохранение и многое другое. Дальнейшие исследования в этой области могут привести к разработке более точных и эффективных методов обнаружения аномалий, способствуя улучшению качества анализа данных и принятия более информированных решений.

Список литературы:

1. Chandola V. Anomaly detection: A survey / V. Chandola, A. Banerjee, V. Kumar // ACM Computing Surveys. – 2009. – Vol. 41, № 3. – Article 15. – DOI: 10.1145/1541880.1541882.
2. Aggarwal C. C. Outlier Analysis / C. C. Aggarwal. – 2nd ed. – Cham : Springer, 2017. – DOI: 10.1007/978-3-319-47578-3.
3. Pang G. Deep learning for anomaly detection: A review / G. Pang, C. Shen, L. Cao, A. van den Hengel // ACM Computing Surveys. – 2022. – Vol. 54, № 2. – Article 38. – P. 1–38. – DOI: 10.1145/3439950.
4. Darban Z. Z. Deep learning for time series anomaly detection: A survey / Z. Darban, G. I. Webb, S. Pan, C. C. Aggarwal, M. Salehi // ACM Computing Surveys. – 2024. – DOI: 10.1145/3691338.
5. Malhotra P. LSTM-based encoder-decoder for multi-sensor anomaly detection / P. Malhotra, L. Vig, G. Shroff, P. Agarwal // arXiv. – 2016. – arXiv:1607.00148. – URL: <https://arxiv.org/abs/1607.00148>. (дата обращения: 01.06.2025).
6. Sakurada M. Anomaly detection using autoencoders with nonlinear dimensionality reduction / M. Sakurada, T. Yairi // Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis. – New York : ACM, 2014. – P. 4–11. – DOI: 10.1145/2689746.2689747.
7. An J. Variational autoencoder based anomaly detection using reconstruction probability / J. An, S. Cho // Special Lecture on IE. – 2015. – Vol. 2, № 1. – P.

- 1–18. – URL: <https://dm.snu.ac.kr/static/docs/TR/SNUDM-TR-2015-03.pdf>.
(дата обращения: 01.05.2025).
8. Zhou C. Anomaly detection with robust deep autoencoders / C. Zhou, R. C. Paffenroth // Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. – New York : ACM, 2017. – P. 665–674. – DOI: 10.1145/3097983.3098052.