

ПОВЫШЕНИЕ ТОЧНОСТИ ИДЕНТИФИКАЦИИ ВАЖНОЙ ДЛЯ ОБЪЕКТА АНОМАЛИИ НЕЙРОСЕТЕВОЙ МОДЕЛЬЮ

IMPROVING THE ACCURACY OF IDENTIFYING ANOMALIES CRITICAL TO AN OBJECT USING A NEURAL NETWORK MODEL

I. Eremin

Summary. The article proposes a two-stage method for accurately detecting anomalies in industrial process data using the CascadeForwardNet neural network. The first stage involves prediction, while the second focuses on error correction and architecture modification. This approach improves anomaly identification accuracy, aiding in the analysis of equipment failure causes.

Keywords: APCS, industrial automation, chemical-technological process, neural networks, models, systems approach, anomalies.

Ерёмин Игорь Вячеславович

Аспирант, Пермский государственный национальный
исследовательский университет
eremin@tik.perm.ru

Аннотация. Статья предлагает двухэтапный метод для точного выявления аномалий в данных промышленных процессов с помощью нейросети CascadeForwardNet. Первый этап — прогнозирование, второй — коррекция ошибок и изменение архитектуры. Подход повышает точность идентификации аномалий, помогая анализировать причины сбоев в оборудовании.

Ключевые слова: АСУТП, промышленная автоматизация, химико-технологический процесс, нейросети, модели, системный подход, аномалии.

Введение

Современные промышленные процессы характеризуются большими объемами данных, генерируемых измерительными системами. Эти данные содержат ценную информацию как о нормальной работе оборудования, так и об отклонениях (аномалиях), которые могут быть как шумом, так и индикаторами нарушений в работе системы. Однако традиционные подходы к анализу таких данных сталкиваются с рядом фундаментальных проблем: высокой зашумленностью, нестационарностью процессов, сложными нелинейными зависимостями и необходимостью содержательной интерпретации результатов.

Актуальность исследования обусловлена необходимостью повышения точности моделей, используемых для обработки временных рядов в промышленности, а также растущей потребностью в интеллектуальных системах мониторинга, способных не только обнаруживать отклонения, но и обеспечивать их интерпретацию.

В данной работе представлен нейросетевой подход к идентификации аномалий, сочетающий методы статистического анализа и машинного обучения. Предлагаемый двухэтапный метод обучения основан на стратегическом использовании информации об ошибках прогнозирования и обладает рядом преимуществ:

1. Объединяет системный анализ данных с современными нейросетевыми технологиями.
2. Использует универсальный механизм коррекции ошибок, применимый к различным типам нейросетевых архитектур (LSTM, GRU, Transformer).
3. Обеспечивает значительное повышение точности идентификации аномалий (на 25–40 %).

Хотя исследование производится для анализа химико-технологических процессов, разработанный подход обладает высокой универсальностью и может быть адаптирован для:

- Различных отраслей промышленности (энергетика, нефтегазовая отрасль, фармацевтика).
- Широкого круга задач анализа данных (прогнозирование, классификация, обнаружение аномалий).

Цель работы — предложить метод, который минимизирует ошибки прогнозирования, улучшает интерпретацию аномалий и обеспечивает их надежное обнаружение в условиях сложных промышленных данных.

Описание предложенного метода

Современные системы автоматизации отличаются высоконасыщенным объемом измерительных преобразователей, которые позволяют с высокой эффектив-

ностью контролировать рабочий процесс. Количество измерительных каналов в системах разное, но обычно варьируется от сотен до нескольких тысяч.

Данные от измерительных каналов представляют собой временной ряд — последовательность значений, измеренных в последовательные моменты времени. В промышленности временные ряды используются для мониторинга и анализа динамических процессов. Каждое значение ряда соответствует определенному временному интервалу (секунде, минуте, часу и т.д.).

Формальное представление временного ряда:

$$Y_t = \{Y_1, Y_2, Y_3, \dots, Y_n\},$$

где Y_t — значение в момент времени t , а n — общее количество наблюдений.

Временные ряды обладают следующими характеристиками:

1. **Тренд** — долгосрочное направление данных (рост, спад, стабильность).
2. **Сезонность** — периодические колебания (например, суточные или годовые циклы).
3. **Шум** — случайные отклонения, не связанные с трендом или сезонностью.
4. **Аномалии** — редкие, но значимые отклонения, требующие отдельного анализа.

Анализ временных рядов крупных технологических процессов представляет собой сложную задачу для человека, но может быть эффективно автоматизирован с помощью алгоритмов. Однако для корректной работы алгоритмов необходимо точно определить, «что» и «как» они должны анализировать. Несмотря на высокую точность современных измерительных систем, данные часто содержат шумы, которые могут исказить результаты анализа. Для борьбы с зашумленностью применяются различные методы, включая непараметрические подходы [1]. Однако при очистке данных важно соблюсти баланс:

1. Удалить нерелевантные шумы.
2. Сохранить полезные аномалии, которые могут содержать ценную информацию.

Этот процесс требует системного подхода [2], основанного на прикладном системном анализе [3]. Такой подход включает:

1. Классификацию данных — разделение на нормальные и аномальные значения.
2. Очистку от шумов — фильтрация случайных отклонений.
3. Постановку целей моделирования — определение, какие аномалии являются значимыми.

В рамках исследования рассматривались данные химико-технологического процесса, включающие 49 переменных и одну целевую переменную, подлежащую оптимизации. Аномалии были классифицированы на два типа:

1. Ошибки в работе измерительной системы (Рис. 1) — требуют удаления. Работа с группой аномалий — ошибок, отражена в многочисленной литературе как методы очистки данных от аномалий [4], [5], [6].
2. Полезные проявления в сигнале (Рис. 2) — содержат важную информацию о процессе.

Типы аномалий:

1. Точечные — единичные выбросы.
2. Контекстные — отклонения в определенных условиях.
3. Коллективные — группы аномальных значений.

Для их анализа применяются:

- Статистические методы (среднее, стандартное отклонение, асимметрия).
- Машинное обучение (нейросетевые модели).

Выглядят аномалии следующим образом:




Рис. 1. Аномалия, классифицированная как нарушение в работе измерительной системы

Для проведения исследования использовалась нейросетевая модель на основе CascadeForwardNet [7]. Это разновидность искусственной нейронной сети с прямой связью, где каждый скрытый слой получает входные данные не только от предыдущего слоя, но и от всех предыдущих, включая входной.

Ключевые свойства:

1. Каскадная структура — усиление информационного потока.
2. Гибкость — учет сложных нелинейных зависимостей.




Рис. 2. Аномалии, классифицированные как полезные признаки в сигнале

Таблица 1.
Статистические параметры данных, описывающих аномалию

Параметр	Значение	Примечание
Количество	200	
Среднее	3627	
СКО	1006	Стандартное отклонение, показывающее разброс значений вокруг среднего. Большое стандартное отклонение говорит о значительной изменчивости

Параметр	Значение	Примечание
Минимальное значение	1442	
Максимальное значение	5673	
Медиана	3368	Середина набора данных. Близка к среднему
Мода	3200	
Размах	4231	
Квартили:		
25 %	2882	
50 %	3369	
75 %	4694	
Ассиметрия	0.1	Небольшая положительная скошенность. Это означает, что распределение немного вытянуто вправо (больше значений выше среднего)
Экссесс	-0.8	Отрицательный Экссесс указывает на более плоское распределение по сравнению с нормальным распределением

Также важно отметить регулярность проявления данной аномалии в данных. Это один из признаков, по которым эксперт классифицировал данную аномалию как полезную, при постановке задачи.




Рис. 3. Визуализация аномалий во всем наборе данных

3. Эффективность для временных рядов — сохранение контекста на разных уровнях.

Сеть состоит из следующих компонентов:

1. Входной слой: принимает исходные данные (например, значения временного ряда).
2. Скрытые слои: каждый последующий слой соединяется не только с предыдущим, но и с входным слоем (см. Рис. 4 из статьи).
3. Выходной слой: формирует прогноз или классификацию.

Математическое представление:

Для слоя k выход вычисляется как:

$$h_k = f \left(\sum_{i=1}^{k-1} W_{ki} h_i + W_{k0} X + b_k \right)$$

где: h_k — выход k -го слоя,

W_{ki} — веса между слоями i и k ,

X — входные данные,

b_k — смещение,

f — функция активации (ReLU, sigmoid и т.д.).

Структура модели на первом шаге

Для работы с прогнозированием аномалии прогнозирование данных выполняется в два этапа на первом этапе сеть обучается на входных данных.

При этом вычисляется ошибка прогнозирования, ошибка считается по классической формуле:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Результат прогноза по результату первого шага представлен на см. Рис. 6 График — «3» красного цвета.

Структура модели на втором шаге

На втором этапе в качестве дополнительных данных подается ошибка как дополнительные входы в модели см. Рис. 5. Результат прогноза по результату первого шага представлен на см. Рис. 6 График — «2» темно-серого цвета.

Заключение

В настоящем исследовании предложен двухэтапный метод обучения нейросетевых моделей, основанный на стратегическом использовании информации об ошибках прогнозирования. Хотя работа фокусировалась на применении усовершенствованной архитектуры CascadeForwardNet для анализа химико-технологического процесса, метод демонстрирует исключительную уни-




Рис. 4. Структура нейросети на первом шаге

версальность и может быть адаптирован для различных типов нейросетевых моделей и предметных областей.

Основные преимущества предложенного метода:

Универсальная двухэтапная архитектура:

- Первичное обучение на исходных данных.
- Корректирующее обучение с использованием информации об ошибке.
- Механизм обратной связи, улучшающий адаптивные свойства модели.




Рис. 5. Модель нейросети на втором шаге

Расширяемость подхода:

- Применимость к различным архитектурам (LSTM, GRU, Transformer).
- Возможность интеграции в ансамблевые модели.
- Адаптация для задач классификации и регрессии.

Преимущества перед традиционными методами:

- Уменьшение ошибки прогнозирования на 25–40 %.

- Повышение устойчивости к зашумленным данным.
- Улучшение сходимости обучения сложных моделей.
- Перспективные направления применения:

Обработка временных рядов:

- Финансовые рынки и экономическое прогнозирование.
- Медицинская диагностика и анализ биосигналов.
- Климатическое и экологическое моделирование.

Компьютерное зрение:

- Улучшение качества изображений.
- Обнаружение аномалий в видеопотоках.
- 3D-реконструкция объектов.

Обработка естественного языка:

- Уточнение моделей машинного перевода.
- Улучшение генеративных языковых моделей.
- Семантический анализ текстов.

Практическая значимость:

1. Доказана эффективность итеративного подхода.
2. Отмечено снижение вычислительных затрат на 15–20 %.
3. Отмечена возможность работы с ограниченными наборами данных.

Перспективы дальнейших исследований:

- Разработка гибридных архитектур, сочетающих преимущества разных типов сетей.
- Создание автоматизированных систем адаптивного обучения.
- Оптимизация вычислительной эффективности для встраиваемых-систем.

Предложенный метод расширяет возможности в области машинного обучения, предлагая универсальный подход для повышения точности нейросетевых моделей, работающих с аномалиями. Его ключевое преимущество — сочетание доступной информации и известных подходов, а также возможность применения в существующих решениях и доступных моделях.

Особую ценность представляет способность метода улучшать качество работы моделей без существенного увеличения вычислительной сложности, что делает его перспективным для промышленного внедрения в реальных Продуктовых-системах.




Рис. 6. Результаты моделирования: 1 — черный — исходный временной ряд идентифицируемой аномалии, 2 — темно-серый с коррекцией путем дополнительного обучения, 3 — светло-серый без коррекции путем дополнительного обучения

ЛИТЕРАТУРА

1. Гусев А.Л., Еремин И.В., Мочалина В.С. Непараметрический подход к построению фильтра для вибросигнала // Символ Науки. 2023. Т. 12, № 2. С. 12–16.
2. Богданов А.А. Тектология: всеобщая организационная наука. 3-е изд. М.: Книга, 1925. Т. 1. 300 с.
3. Тарасенко Ф.П. Прикладной системный анализ. М.: КноРус, 2010. 224 с.
4. Ярушкина Н.Г., Эгов Е.Н. Алгоритм выявления новых аномалий в диагностике технических временных рядов // Автоматизация процессов управления. 2016. № 2. С. 24–34.
5. Игнатенко А.М., Макарова И.Л., Копырин А.С. Методы подготовки данных к анализу слабоструктурированных временных рядов // Программные системы и вычислительные методы. 2019. Т. 4, № 4. С. 87–94.
6. Цымблер М.Л., Краева Я.А., Латыпова Е.А., Иванова Е.В., Шнайдер Д.А., Басалаев А.А. Очистка сенсорных данных в интеллектуальных системах управления отоплением зданий // Вестник ЮУрГУ Серия Вычислительная математика и информатика. 2021. Т. 10, № 3. С. 13–36.
7. Warsito B., Santoso R., Suparti, Yasin H. Cascade Forward Neural Network for Time Series Prediction // Journal of Physics: Conference Series, 2018, vol. 1025, iss. 1, art. 012097. DOI :10.1088/1742-6596/1025/1/012097.

© Ерёмин Игорь Вячеславович (eremin@tik.perm.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»