

ОБНАРУЖЕНИЕ АНОМАЛИЙ В РАБОТЕ РЕАКТОРНОГО ОБОРУДОВАНИЯ С ПОМОЩЬЮ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ

Е.Л. Трыков *, И.В. Трыкова **, К.И. Коцоев **

** АО «НТЦ Диапром»*

249031, Калужская обл., г. Обнинск, ул. Королева, д. 6, пом. 22-23

*** ООО «КВАНТ ПРОГРАММ»*

111558, г. Москва, Зеленый проспект, д. 5/12, стр. 3, пом. Б1



Проблема обнаружения аномалий алгоритмами, основанными на методах машинного обучения и, в частности, на нейросетевых методах, в последнее время очень актуальна во многих отраслях промышленности, в том числе и в атомной энергетике.

Поэтому крайне актуальным становится внедрение предиктивных аналитических систем в целях углубленной обработки данных технологического контроля для раннего обнаружения неисправностей оборудования, а также для анализа его ресурсных характеристик.

Основной задачей предиктивной аналитики является построение и оптимизация цифровой модели для поиска аномалий в работе оборудования, определение временного интервала безаварийной работы оборудования и корректировка объема технического обслуживания и ремонта. Предлагается алгоритм обнаружения аномалий в работе оборудования, основанный на использовании нейронных сетей. Эффективность разработанного алгоритма демонстрируется на примере работы четырех ГЦН блока № 6 Нововоронежской АЭС.

Разработанный алгоритм демонстрирует высокую чувствительность к изменению режимов работы ГЦН и позволяет следить за их работой как в онлайн-, так и в офлайн-режимах. Реализация разработанной методики возможна в рамках системы комплексной диагностики (СКД), поставляемой АО «НТЦ Диапром» на различные АЭС.

Ключевые слова: нейронные сети, временные ряды, аномалии работы реакторного оборудования, система технической диагностики оборудования АЭС.

ВВЕДЕНИЕ

Существующая система технической диагностики оборудования АЭС заключается во взаимодополняющем применении систем оперативного диагностирования в процессе эксплуатации и средств неразрушающего контроля в процессе планово-предупредительных ремонтов (ППР).

Как правило, оперативное диагностирование направлено не на долгосрочное прогнозирование состояния оборудования, а на решение задачи «здесь и сейчас» по

© *Е.Л. Трыков, И.В. Трыкова, К.И. Коцоев, 2020*

мгновенному временному срезу многоканальных измерений. Неразрушающий контроль, поставляя большую глубину диагностирования, не обеспечивает требуемую достоверность обнаруживаемых аномалий.

Однако в настоящее время в атомной отрасли все шире применяются методы предиктивной аналитики в задачах диагностики [1]. Предлагаемый здесь подход состоит в обучении нейронной сети на довольно большом временном интервале работы блока АЭС в стационарном номинальном (100%-ом) режиме функционирования, например, в течение нескольких месяцев с довольно мелким временным шагом в несколько десятков минут. Речь идёт о так называемых *больших данных* (Big Data), которые в настоящее время не анализируются системами оперативного диагностирования. При этом мощность блока, действительно, представляет собой практически стационарный временной ряд, а некоторые другие измеряемые параметры (например, концентрация борной кислоты или перемещения органов управления), напротив сугубо нестационарные процессы. Обученная такими векторными синхронно измеренными процессами нейронная сеть представляет собой виртуальную модель объекта диагностирования, латентное пространство которой хоть и не имеет физической интерпретации, но несет информацию о нормальном (проектном) функционировании объекта.

Любая аномалия (дефект, отказ, исчерпание ресурса) в измерениях проявляется в виде нестационарности некоторых наблюдаемых временных рядов. Это не только мгновенные скачки амплитуды измерений, но и медленные тренды, практически невидимые за время наблюдений. Необходимо отличать штатную нестационарность от аномальной нестационарности. Правильно обученная и правильно выбранная нейронная сеть «знает» штатную нестационарность и способна выявить новую нестационарность как аномальное состояние объекта диагностирования.

К недостаткам традиционных нейронно-сетевых методов зачастую относят необходимость обучения с учителем. Поэтому в последнее время возрос интерес к методам обучения без учителя, а именно: вариационного автоэнкодера (ВАЭ) [2] и состязательных генеративных сетей [3]. В данной работе для обнаружения аномалий используется ВАЭ [2]. На вход ВАЭ подаются исследуемые данные, которые, проходя через структуру нейронной сети, преобразуются в выходные «восстановленные» данные, воспроизводящие входные данные с высокой точностью для системы в нормальном состоянии. По сравнению с входным вектором измерений латентное пространство ВАЭ намного меньше по размерности, т.е. внутри ВАЭ происходит сжатие входной информации, но при этом сохраняется наиболее важная диагностическая информация об объекте. Такая особенность работы ВАЭ выгодно отличает его от более простых нейронно-сетевых методов, в которых нет критерия достоверности виртуальной модели объекта, полученной субъективным обучением.

Весовые коэффициенты ВАЭ получены в процессе обучения на данных без аномалий. Далее определяется ошибка восстановления (невязка) между входными и выходными данными. Идея использования ВАЭ заключается в том, что в процессе обучения на «нормальных» данных весовые коэффициенты подбираются таким образом, чтобы ошибка восстановления «нормальных» данных была гораздо меньшей по сравнению с ошибкой восстановления «аномальных данных». Кроме того, ВАЭ позволяет получить вероятностные характеристики распределения восстановленных данных, которые также могут быть использованы для детектирования аномалий.

В данной работе для обнаружения аномалий

- реализован ВАЭ с механизмом внимания на основе двунаправленных рекуррентных нейронных сетей, использующий гауссово распределение для представления латентных переменных, определяющих внутреннюю структуру исследуемых временных рядов [2];
- использована вероятностная реконструкция исходных величин, что позволяет опре-

делять параметры распределения вероятностей восстановленных величин;
 – построен обнаружитель по восстановленным данным аномалий на основе T^2 -статистики.

ПРЕДЛАГАЕМАЯ МОДЕЛЬ

Рекуррентные нейронные сети LSTM, Bi-LSTM

Рекуррентные нейронные сети (РНС) [4] являются мощным средством анализа временных рядов благодаря способности «накапливать» внутреннее состояние, они способны изучать долговременные зависимости в последовательно поступающих данных.

Сети долгой краткосрочной памяти (Long Short-Term Memory – LSTM), первоначально представленные в [5], являются разновидностью РНС и отличаются улучшенным воспроизведением долговременных зависимостей.

Двунаправленные Bi-LSTM (Bidirectional LSTM) [6] на каждой эпохе обучения производят «двойной» проход по входным данным $\mathbf{x} = (x_{t_0}, x_{t_1}, \dots, x_{t_T})$ – сначала в прямом направлении по времени, от t_0 к t_T , затем в обратном – от t_T к t_0 . Bi-LSTM-сети за счет более детальной обработки временного ряда (рекуррентный проход в прямом и обратном направлениях), способны точнее запоминать характеристики входных данных.

Механизмы внимания

Механизмы внимания [7 – 13] – это подход в машинном обучении, заключающийся в выделении части входных данных для более детальной обработки. Применение механизмов внимания позволяет улучшить выделение характеристических особенностей временных рядов благодаря информации, полученной из взвешенной суммы всех скрытых состояний РНС. Различают два типа механизмов внимания: глобальное внимание, которое акцентируется на всей последовательности входных данных, и локальное, учитывающее только некоторую окрестность текущего состояния. В данной работе используется глобальное внимание.

Автоэнкодеры

Автоэнкодеры [14, 15] – это нейронные сети прямого распространения, которые на выходе восстанавливают входные данные. Автоэнкодеры конструируются таким образом, чтобы не иметь возможности точно скопировать входные данные на выходе. Обычно это достигается за счет уменьшения размерности скрытых слоев. Входные данные восстанавливаются с потерями при кодировании, но для их минимизации сеть вынуждена учиться отбирать наиболее важные признаки.

Ошибка восстановления данных автоэнкодером рассматривается как оценка аномалий, и образцы с высокой ошибкой реконструкции рассматриваются как аномалия. На этапе обучения используются только нормальные данные, чтобы свести к минимуму ошибки реконструкции для данных, где, как считается, нет аномалий. На этапе тестирования обученный автоэнкодер сможет с минимальными ошибками восстановить нормальные исходные данные, в то время как аномальные исходные данные, с которыми автоэнкодер не сталкивался раньше, будут иметь относительно высокую погрешность реконструкции по сравнению с нормальными данными. Таким образом, путем сравнения ошибки реконструкции с определенным порогом автоэнкодер может определить, являются ли тестируемые данные аномальными. В статье рассматриваются только вариационные автоэнкодеры.

Вариационные автоэнкодеры [16 – 17] относят к семейству генеративных моделей. На вход энкодера подаются наблюдаемые данные $\mathbf{x} \in \mathbb{R}^{d_x}$, $\mathbf{x} \sim p(\mathbf{x})$, которые затем отображаются в латентное пространство $\mathbf{z} \in \mathbb{R}^{d_z}$, $\mathbf{z} \sim p(\mathbf{z})$. На вход декодера подаются семплированные из $p(\mathbf{z})$ объекты. Таким образом, энкодер для каждого \mathbf{x} предсказывает два значения – среднее μ и дисперсию σ нормального распределения, из которого уже сэмпляются значения латентной переменной \mathbf{z} .

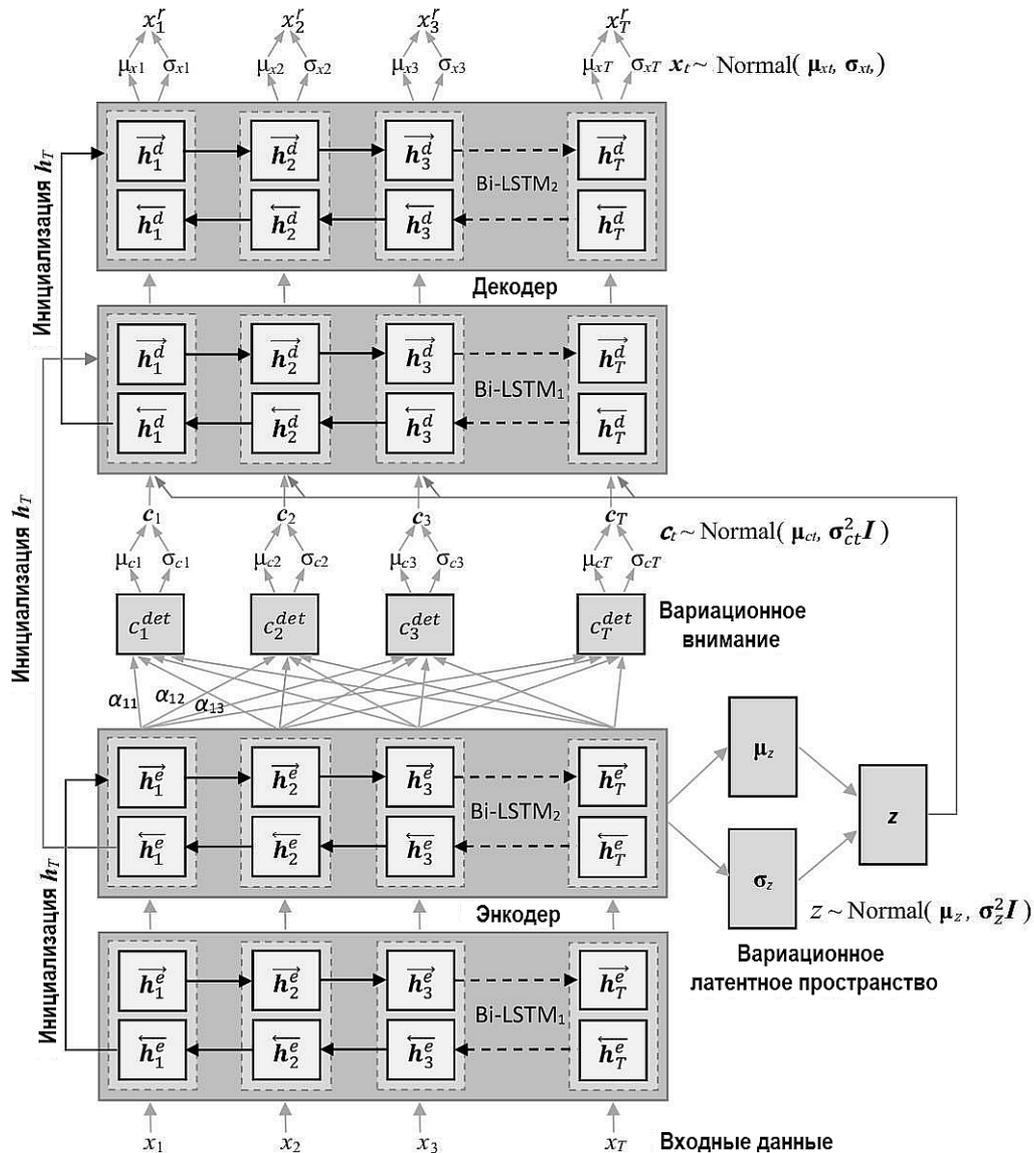


Рис. 1. Схема предлагаемого вариационного автоэнкодера

Предлагаемая модель ВАЭ

Для детектирования аномалий использовался разработанный вариационный автоэнкодер с вариационным вниманием, схема которого изображена на рис. 1. Кроме того использовался алгоритм восстановления вероятности, когда на выходе декодера получают не только сам восстановленный $x^r(t)$, а еще и параметры его распределения (которое полагается нормальным). Это позволило построить доверительные интервалы для восстановленных сигналов, являющихся нормальными.

Обучение модели

Обучающие данные были приведены к единому интервалу отсчетов по времени (1 час) и стандартизованы (приведены к среднему = 0 и дисперсии = 1).

Обучение ВАЭ производилось путем минимизации функции потерь методом стохастического градиентного спуска. Переменные латентного пространства семплировались

L раз ($L=1$ при обучении модели и $L=50$ при детектировании аномалий).

Стандартизация входных данных

При обучении ВАЭ для обеспечения сходимости метода градиентного спуска требуется стандартизация исходных данных. Данные были стандартизированы при помощи функции Sklearn пакета StandardScaler, т.е. приведены к среднему = 0 и дисперсии = 1 по формуле

$$\mathbf{x}'' = (\mathbf{x} - \mu(\mathbf{x})) / \sigma(\mathbf{x})$$

на трейновой выборке. Полученные параметры StandardScaler далее применялись для тестовой выборки. Этот метод стандартизации применим в предположении, что статистика входных данных в полной мере определяется трейновой выборкой и далее не меняется. Все отклонения от статистики трейновой выборки воспринимаются моделью как «аномалии», в том числе тренды, что можно применить при исследовании, например, ресурса оборудования на длинных временных промежутках, когда происходят медленные изменения параметров (старение). Заметим, что указанная процедура стандартизации не подходит для детектирования заведомо нестационарных (но «нормальных») процессов, например, перепада давления на ГЦН или изменения мощности ГЦН. Подобные процессы нуждаются в приведении к стационарному виду (удаление трендов), что ведёт к потере части информации.

Удаление трендов производилось в три этапа:

- сглаживание по 20-ти точкам исходного сигнала методом скользящего среднего;
- численное дифференцирование по трем точкам сглаженного сигнала;
- применение фильтра Савицкого-Голея.

Детектирование аномалий

Детектирование аномалий по сумме невязок. Стратегия детектирования аномалий по невязкам базируется на следующих принципах. ВАЭ обучается на «нормальных» данных и таким образом выучивает характерные паттерны «без аномалий». «Нормальные» данные, в итоге, хорошо восстанавливаются и невязка между исходными данными и восстановленными мала. В случае аномальных данных, ВАЭ не в состоянии их восстановить с той же погрешностью, что и нормальные данные. Это приводит к увеличению невязки между входными и восстановленными данными.

В качестве интегрального критерия наличия аномалий была взята сумма невязок

$$S(t) = \sum_{k=1}^N |\mathbf{x}_k(t) - \mathbf{x}_k^r(t)|, \quad (1)$$

где N – количество временных рядов; $\mathbf{x}_k(t)$ – входные данные; $\mathbf{x}_k^r(t)$ – восстановленные данные.

Далее по интервалу $t_0 \leq t \leq t_{\text{end}}$ строилась гистограмма $S(t)$. При наличии аномалий хотя бы по одному временному ряду, сумма невязок резко возрастает, что приводит к пространственному разделению гистограмм для трейновой выборки и аномальных данных.

Детектирование аномалий по доверительным интервалам. Данный критерий позволяет определить, какой конкретно временной ряд «аномален».

Для оценки наличия аномалии использовался трехшаговый алгоритм:

- для каждой точки ряда $\mathbf{x}(t)$ из обученного декодера извлекалось среднеквадратичное отклонение $\sigma_{\mathbf{x}(t)}$;
- в каждой точке ряда $\mathbf{x}(t)$, согласно правилу «трёх сигм», строились доверительные границы: нижняя $\mathbf{lower}(t) = \mathbf{x}^r(t) - 3\sigma_{\mathbf{x}(t)}$ и верхняя $\mathbf{upper}(t) = \mathbf{x}^r(t) + 3\sigma_{\mathbf{x}(t)}$;
- значение ряда $\mathbf{x}(t_0)$ в точке считается аномалией, если $\mathbf{x}(t_0) < \mathbf{lower}(t_0)$ или $\mathbf{x}(t_0) > \mathbf{upper}(t_0)$.

T^2 - и Q -КРИТЕРИИ

T^2 -критерий фактически является расстоянием Махаланобиса между вектором состояния $\mathbf{X}_n^{1 \times D}$ и вектором средних $\bar{\mathbf{x}}^{1 \times D}$ трейновой выборки. Для расчета T^2 -критерия на основе метода главных компонент схема расчета следующая: для трейновой выборки (аномалий нет) рассчитываются вектор средних и вектор стандартных отклонений. Далее для центрированных данных применяется преобразование главных компонент (РСА) и находится матрица перевода. После этого данные тестовой выборки нормализуются с использованием векторов средних и стандартных отклонений для трейновой выборки. Далее нормализованная тестовая выборка преобразуется в подпространство главных компонент с параметрами преобразования, определенными по трейновой выборке. Для преобразованных данных рассчитывается T^2 -критерий. Формулы для расчета T^2 -критерия и значения допустимого предела T^2_{UCL} приведены в [18]. Q -критерий позволяет обнаруживать изменения в данных в подпространстве оставшихся компонент (подпространство разностей) после перевода исходных данных в подпространство главных компонент. Q -критерий для i -го измерения определяется по формуле [19]

$$Q_i = \mathbf{x}_i \cdot (\mathbf{I} - \mathbf{P} \cdot \mathbf{P}^T) \cdot \mathbf{x}_i^T, \quad (2)$$

где \mathbf{P} – матрица преобразования в пространство главных компонент.

Допустимое значение для критерия Q_{UCL} рассчитывается по формуле, приведенной в [19].

РЕЗУЛЬТАТЫ

Проведен поиск отклонений состояния для четырех ГЦН НВАЭС-2 от начала третьей кампании (03.07.2019 г.) до начала 2020 г. Как видно из рис. 2, за это время был один сброс мощности до 80% (с 17 по 23.11.2019 г.) и один останов реактора (с 29.11.2019 г. по 04.12.2019 г.). В расчетах эти периоды кампании не учитывались (пропуски данных на рисунках ниже).

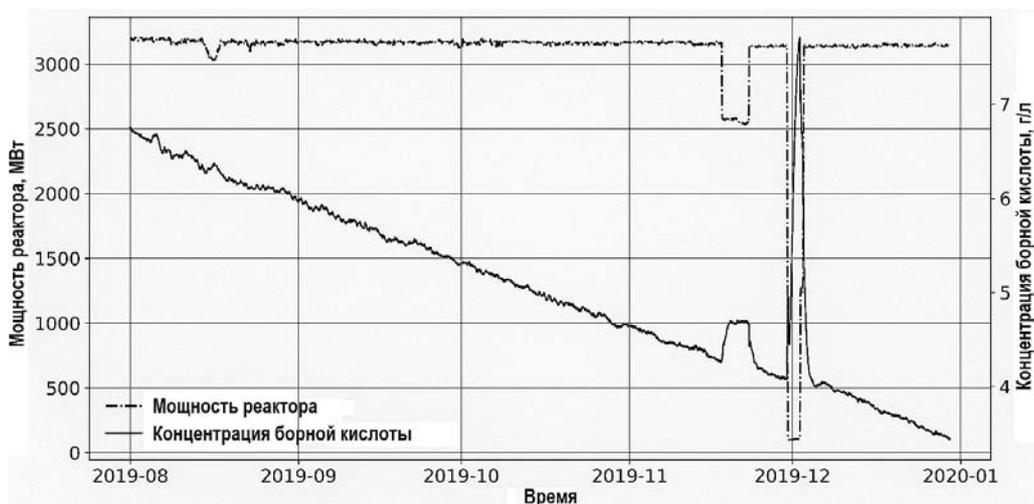


Рис. 2. Активная мощность реактора и концентрация борной кислоты

В расчетах учитывалось по 49 параметров для каждого ГЦН, полученных из СВБУ. Сюда входят вибрационные (виброперемещения), электрические (ток и мощность ГЦН) и технологические (температура, давление, расход) параметры. Проведена предварительная предобработка данных, описанная выше, для приведения всех временных рядов к единому масштабу.

Ниже приведены примеры детектирования аномалий посредством ВАЭ согласно рас-

смотренным критериям.

Детектирование аномалий по сумме невязок и кластеризация данных

Рассмотрим конкретный пример применения ВАЭ к ГЦН-1.

Применение нейронных сетей для поиска аномалий подразумевает обучение сети на некотором временном отрезке данных, на котором предполагается отсутствие аномалий. В качестве такого участка был выбран период с 01.08.2019 г. по 30.09.2019 г. Здесь надо отметить, что никаких аномалий в работе ГЦН в 2019 г. отмечено не было, и теоретически все рассматриваемые данные являются нормальными, но надо было показать, как предложенный подход отслеживает отклонения от того режима работы ГЦН, который был определён «нормальным», от режима, определяемого трейновой выборкой. Естественно, в реальных условиях ВАЭ будет обучен на всех режимах работы ГЦН, которые считаются нормальными. Эти режимы будут представлять собой некие кластеры в пространстве состояний работы оборудования. В этом случае аномалией будет считаться любой выход параметров работы оборудования за рамки этих кластеров.

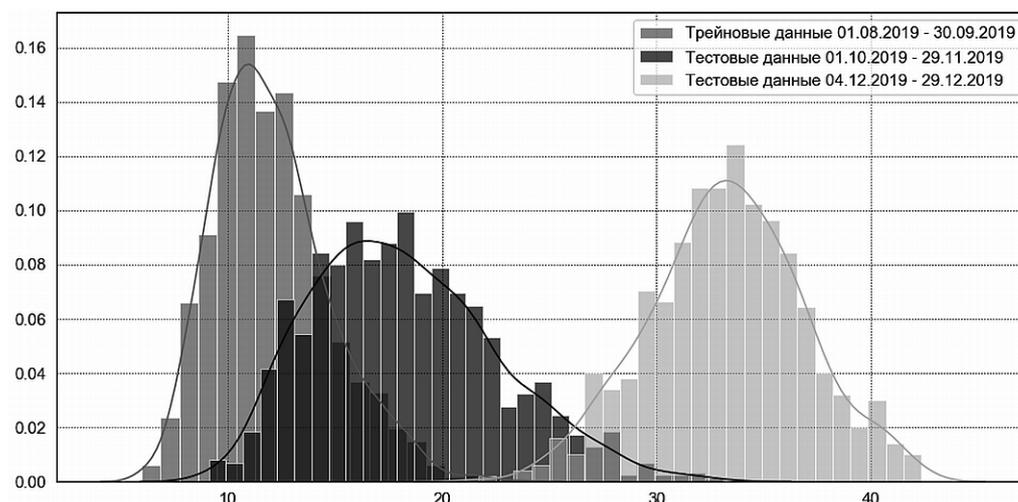


Рис. 3. Гистограммы суммарных невязок за различные периоды работы ГЦН-1

На рисунке 3 показаны гистограммы суммарных невязок для ГЦН-1 за различные периоды работы. Естественно, что период, на котором проходило обучение ВАЭ, с 01.08.2019 г. по 30.09.2019 г. имеет наименьшую сумму невязок.

Периоды с 01.10.2019 г. по 29.11.2019 г. и с 04.12.2019 г. по 29.12.2019 г., очевидно, являются другими режимами работы ГЦН-1.

Детектирование аномалий по доверительным интервалам

Здесь надо отметить, что некоторые из участвующих в рассмотрении временных рядов не являются стационарными по физическим причинам. Это, например, активная мощность ГЦН и перепад давления на нем. Нестационарность этих величин обусловлена изменением концентрации бора в воде на протяжении кампании (см. рис. 3) и, как следствие, изменением плотности воды. Однако стандартизация данных работает таким образом, что при детектировании аномалий любые тренды рано или поздно приводят к выходу за пределы статистики трейновой выборки, поэтому эти ряды сначала дифференцируются по времени, а затем стандартизируются. Естественно, для сравнения с исходными величинами к рассчитанным параметрам должна быть применена инверсная процедура (кумулятивное суммирование).

Рассмотрим результаты применения ВАЭ к продифференцированному сигналу активной мощности ГЦН-1. Из рисунка 4 видно, что на всем протяжении рассматриваемой кампании этот сигнал находится в пределах доверительного интервала. На рисунке 5

приведены сам сигнал и рассчитанная с помощью ВАЭ невязка, которая в данном случае постоянна на всем рассматриваемом интервале.

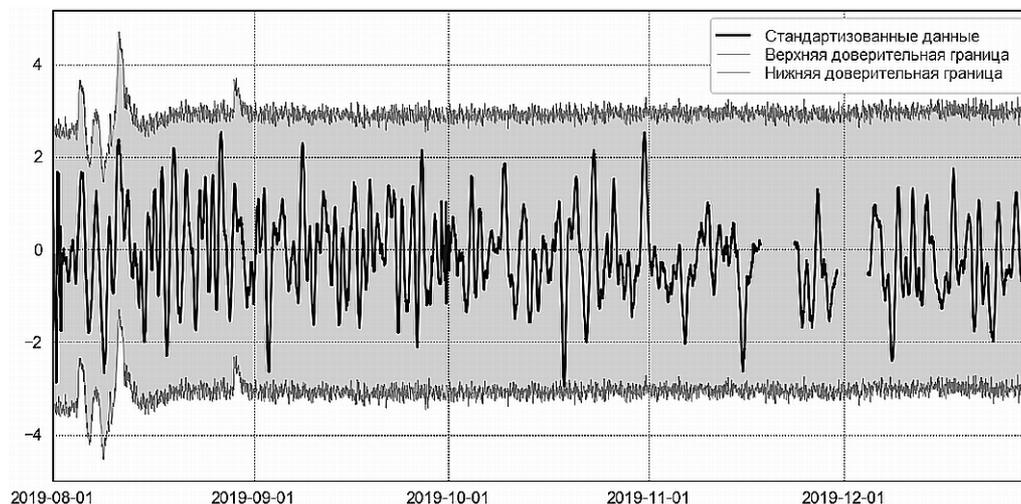


Рис. 4. Доверительные границы и активная мощность ГЦН-1 (удаление тренда)

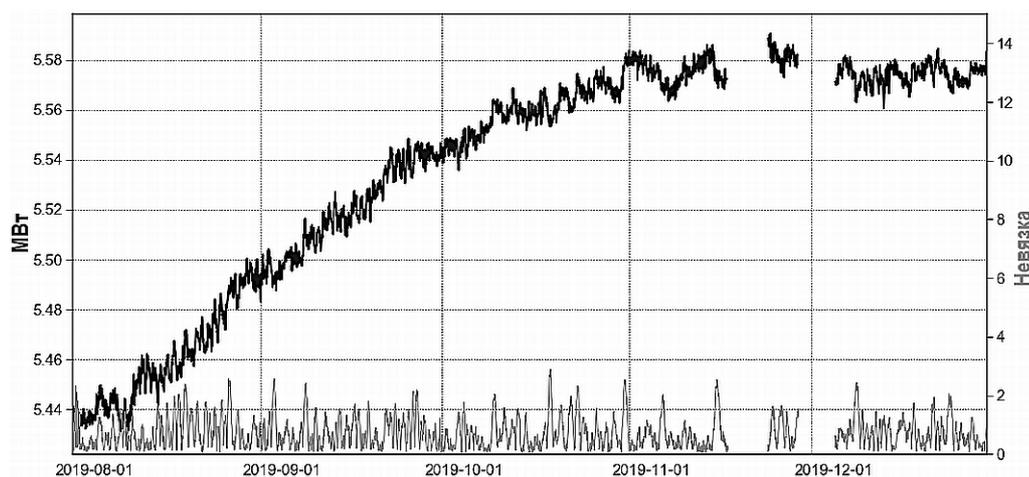


Рис. 5. Активная мощность ГЦН-1 (удаление тренда) и невязка ВАЭ

Совершенно другая картина наблюдается с сигналом расхода на сливе уплотнения ГЦН-1. Сигнал находится в пределах доверительного интервала только до ноября 2019 г., а затем покидает его (рис. 6). Из рисунка 7 видно, что невязка с 01.11.2019 г. имеет устойчивый тренд.

Полученные результаты позволяют нам утверждать, что детектирование аномалий при помощи ВАЭ позволяет выделять устойчивые тренды в изменении параметров работы различного оборудования ГЦН и может быть применено в оценке ресурсных характеристик ГЦН.

Наиболее показательны результаты предложенного подхода могут быть представлены с использованием критерия Хотеллинга (T^2).

Критерий T^2

На рисунке 8 приведена T^2 -статистика по ГЦН-1. Данные результаты полностью соответствуют кластерам гистограмм, показанным на рис. 3.

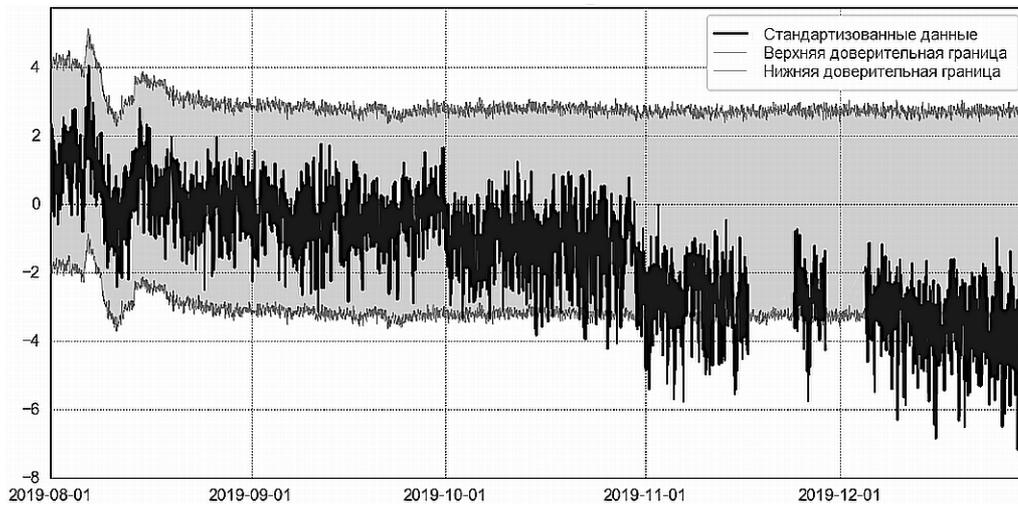


Рис. 6. Доверительные границы и сигнал расхода на сливе уплотнения ГЦН-1. Виден тренд, который после 01.11.2019 будет детектирован как «аномалия» (выход за доверительные границы)

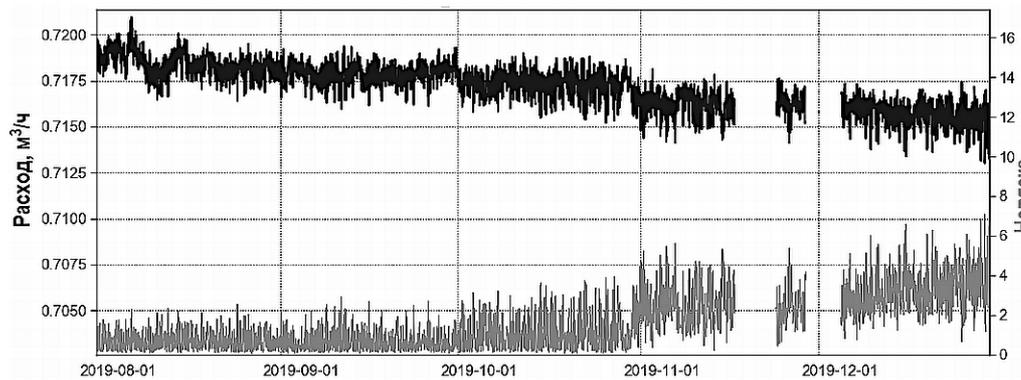


Рис. 7. Сигнал расхода на сливе уплотнения ГЦН-1 и невязка ВАЭ. Невязка показывает наличие тренда

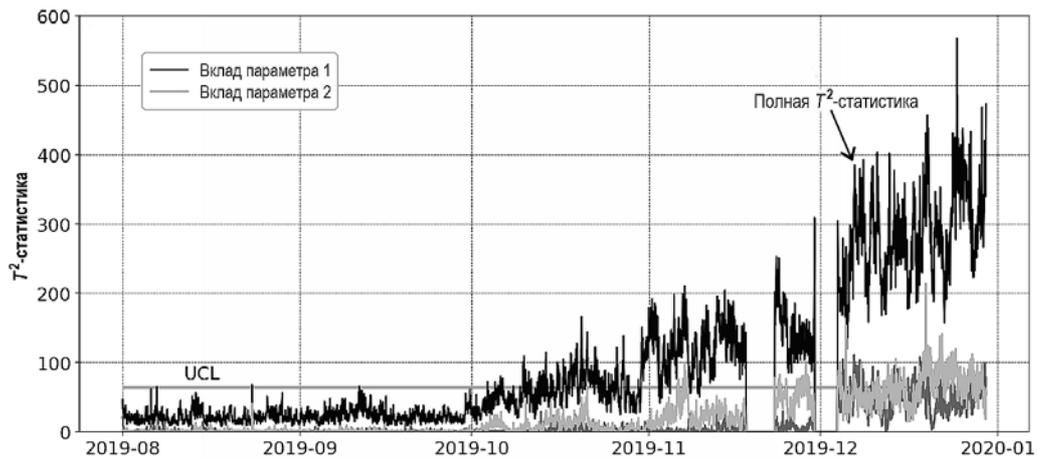


Рис. 8. T^2 -статистика по ГЦН-1 и вклад основных параметров (1 – ток на электромагните; 2 – температура слива на уплотнении)

Одним из важных достоинств критерия Хотеллинга является возможность расчета того, какой вклад каждый отдельный временной ряд вносит в общую величину T^2 -статистики. Данный подход описан в работе [20]. На рисунке 8 приведена T^2 -статистика

для двух основных параметров, которые вносят наибольший вклад в эту статистику.

Видно, что этот критерий очень чувствителен к малейшим изменениям нормированных невязок, и может быть очень полезен как при выявлении аномалий в работе оборудования, так и в расчете его ресурсных характеристик.

ВЫВОДЫ

Метод определения аномалий в работе оборудования с использованием ВАЭ является весьма эффективным, что продемонстрировано на примере описания режимов работы ГЦН НВАЭС.

Предлагаемые новые многомерные предиктивные характеристики могут быть использованы для оценки остаточного ресурса оборудования наравне с ресурсными характеристиками, регламентированными ГОСТ.

В настоящее время в системе комплексной диагностики (СКД, поставщик АО «НТЦ Диапром») на НВАЭС наращиваются функции контроля остаточного ресурса предиктивными методами.

Литература

1. Предиктивная аналитика и диагностика АЭС. Библиотека технической диагностики атомных электростанций. / Под ред. В. И. Павелко. – Москва: АО «НТЦД», 2019. – 69 с.
2. Kingma D.P., Welling M. Auto-Encoding Variational Bayes. // arXiv preprint. – 2014, arXiv:1312.6114v10. – 14 p.
3. Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press. – 2016. – 787 p.
4. Yao K., Cohn T., Vylomova K., Duh K., Dyer C. Depth-Gated LSTM. // arXiv preprint. – 2015, arXiv:1508.03790v4. – 6 p.
5. Hochreiter S., Schmidhuber J. Long Short-Term Memory. // Neural Computation. – 1997. – Vol. 9, pp. 1735-1780; DOI: 10.1162/neco.1997.9.8.1735 .
6. Graves A., Schmidhuber J. Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures. // Neural networks. – 2005. – Vol. 18. – PP. 602-610; DOI: 10.1016/j.neunet.2005.06.042 .
7. Luong M., Pham H., Manning C. Effective approaches to attention-based neural machine translation. // arXiv preprint. – 2015, arXiv:1508.04025. – 11 p.
8. Bahdanau D., Cho K., Bengio Y. Neural machine translation by jointly learning to align and translate. // arXiv preprint. – 2014, arXiv:1508.04025v7. – 15 p.
9. Pereira J., Silveira M. Unsupervised anomaly detection in energy time series data using variational recurrent autoencoders with attention. – 2018 XVII-th IEEE International Conference on Machine Learning and Applications (ICMLA). – 2018. – 8 p. DOI: 10.1109/ICMLA.2018.00207 .
10. Bahuleyan H., Mou L., Vechtomova O., Poupart P. Variational attention for sequence-to-sequence models. // arXiv preprint. – 2018, arXiv:1712.08207v3. – 11 p.
11. Польшковский Д.А. Attention Mechanisms in Neural Networks. Final qualifying work. – М.: МГУ им. М.В.Ломоносова, 2017. – 22 с.
12. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser L. Attention is all you need. // arXiv preprint. – 2017, arXiv:1706.03762v5. – 11 p.
13. Luong M. Neural machine translation. – Thesis PHD. December 2016. – 156 p.
14. Pereira J. Unsupervised Anomaly Detection in Time Series Data using Deep Learning. / Thesis to obtain the Master of Science Degree in Electrical and Computer Engineering. – 2018. – Técnico Lisboa. – 67 p.
15. Rumelhar, D.E. Hinton G.E., Williams R.J. Learning Representations by Backpropagating Errors. // Nature. – 1986. – Vol. 323. – PP. 533-536; DOI: 10.1038/323533a0 .
16. An J., Cho S. Variational Autoencoder based Anomaly Detection using Reconstruction Probability. // arXiv preprint. – 2015, arXiv:1802.03903v1. – 12 p.
17. Zhang C., Chen Y. Time Series Anomaly Detection with Variational Autoencoders. // arXiv preprint. – 2019, arXiv:1907.01702v1. – 7 p.

18. *Mujica L.E., Rodellar J., Fernandez A., Guemes A.* Q-statistic and T^2 -statistic PCA-based measures for damage assessment in structures. // *Structural Health Monitoring*. – 2010. – Vol. 10. – No. 5. – PP. 539-553.

19. *Jackson J., Mudholkar S.* Control Procedures for Residuals Associated With Principal Component Analysis. // *Technometrics*. – 1979. – Vol. 21. – No. 3. – PP. 341-349.

20. *Runger G. Alt, F., Montgomery D.* Contributors to a Multivariate Statistical Process Control Chart Signal. // *Communications in Statistics. Theory and Methods*. – 1996. Vol. 25. – Iss. 10. – PP. 2203-2213.

Поступила в редакцию 20.05.2020 г.

Авторы

Трыков Евгений Львович, к.ф.-м.н.

E-mail: trykov@diaprom.ru

Трыкова Ирина Владимировна, программист

E-mail: trykova@kvantprogramm.ru

Коцюев Константин Игоревич, инженер

E-mail: kotsoev@kvantprogramm.ru

UDC 621.039

DETECTION OF ANOMALIES IN THE REACTOR EQUIPMENT OPERATION USING NEURAL NETWORK ALGORITHMS

Trykov E.L. *, Trykova I.V. **, Kotsoev K.I. **

* JSC «STC Diaprom»

6, rooms 22-23 Koroleva Str., 249031 Obninsk, Kaluga Reg., Russia

** «KVANT PROGRAMM» LTD

5/12, bld. 3, room B1 Zeleny Av., 111558 Moscow, Russia

ABSTRACT

The problem of detecting anomalies by algorithms based on machine learning methods, in particular, on neural network methods, has recently been very relevant in many industries, including nuclear energy.

The existing system of technical diagnostics of NPP equipment consists in the additional use of rapid diagnostics systems during operation and non-destructive testing tools during planned preventive repairs (PPR).

In this regard, the introduction of predictive analytical systems for the in-depth processing of process control data for the early detection of equipment malfunctions, as well as for the analysis of its resource characteristics, becomes extremely urgent.

The main task of predictive analytics is to build and optimize a digital model to search for anomalies in equipment operation, determine the time interval for equipment trouble-free operation and adjust the scope of maintenance and repair.

The paper presents an algorithm for detecting anomalies in equipment operation, based on the use of neural networks. The efficiency of the developed algorithm was confirmed by the operation of the MCPs at Unit 6 of the Novovoronezh NPP.

The developed algorithm demonstrates high sensitivity to changes in MCP operation modes and makes it possible to control their operation both online and offline. Implementation of the developed methodology is possible within the framework of the complex diagnostics system (CDS) supplied by JSC «STC Diaprom» to various nuclear power plants.

Key words: neural networks, time series, anomalies in the operation of reactor equipment, the system of technical diagnostics of NPP equipment.

REFERENCES

1. *Predictive Analytics and Diagnostics of Nuclear Power Plants. Library of Technical Diagnostics of Nuclear Power Plants*. Ed. by V. I. Pavelko. Moscow. JSC «NTCD» Publ., 2019, 69 p. (in Russian)
2. Kingma D.P., Welling M. Auto-Encoding Variational Bayes. *arXiv preprint*. 2014, arXiv:1312.6114v10, 14 p.
3. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. MIT Press, 2016. 787 p.
4. Yao K., Cohn T., Vylomova K., Duh K., Dyer C. Depth-Gated LSTM. *arXiv preprint*. 2015, arXiv:1508.03790v4, 6 p.
5. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997, v. 9, pp. 1735-1780; DOI: 10.1162/neco.1997.9.8.1735 .
6. Graves A., Schmidhuber J. Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures. *Neural Networks*. 2005, v. 18, pp. 602-610; DOI: 10.1016/j.neunet.2005.06.042 .
7. Luong M., Pham H., Manning C. Effective approaches to attention-based neural machine translation. *arXiv preprint*. 2015, arXiv:1508.04025, 11 p.
8. Bahdanau D., Cho K. Bengio Y. Neural machine translation by jointly learning to align and translate. *arXiv preprint*. 2014, arXiv:1508.04025v7, 15 p.
9. Pereira J., Silveira M. Unsupervised anomaly detection in energy time series data using variational recurrent autoencoders with attention. 2018 XVII-th IEEE International Conference on Machine Learning and Applications (ICMLA). 2018, 8 p.; DOI: 10.1109/ICMLA.2018.00207 .
10. Bahuleyan H., Mou L., Vechtomova O., Poupart P. Variational attention for sequence-to-sequence models. *arXiv preprint*. 2018, arXiv:1712.08207v3, 11 p.
11. Polykovskiy D.A. *Attention Mechanisms in Neural Networks*. Final Qualifying Work. Moscow. MGU im. M.V. Lomonosova Publ., 2017, 22 p. (in Russian).
12. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser L. Attention is all you need. *arXiv preprint*. 2017, arXiv:1706.03762v5, 11 p.
13. Luong M. *Neural Machine Translation*. Thesis PHD. December 2016. 156 p.
14. Pereira J. *Unsupervised Anomaly Detection in Time Series Data using Deep Learning*. Thesis to obtain the Master of Science Degree in Electrical and Computer Engineering. Tecnico Lisboa Publ., 2018, 67 p.
15. Rumelhar D.E. Hinton G.E., Williams R.J. Learning Representations by Backpropagating Errors. *Nature*. 1986, v. 323, pp. 533-536; DOI: 10.1038/323533a0 .
16. An J., Cho S. Variational Autoencoder based Anomaly Detection using Reconstruction Probability. *arXiv preprint*. 2015, arXiv:1802.03903v1, 12 p.
17. Zhang C., Chen Y. Time Series Anomaly Detection with Variational Autoencoders. *arXiv preprint*. 2019, arXiv:1907.01702v1, 7 p.
18. Mujica L.E., Rodellar J., Fernandez A., Guemes A. Q-statistic and T²-statistic PCA-based measures for damage assessment in structures. *Structural Health Monitoring*. 2010, v. 10, no. 5, pp. 539-553.
19. Jackson J., Mudholkar S. Control Procedures for Residuals Associated With Principal Component Analysis. *Technometrics*. 1979, v. 21, no. 3, pp. 341-349.
20. Runger G. Alt, F., Montgomery D. Contributors to a Multivariate Statistical Process Control Chart Signal. *Communications in Statistics. Theory and Methods*. 1996, v. 25, iss. 10, pp. 2203-2213.

Authors

Trykov Evgeny Lvovich, Information Technology Specialist, Cand. Sci. (Phys.-Math.)

E-mail: trykov@diaprom.ru

Trykova Irina Vladimirovna, Programmer

E-mail: trykova@kvantprogramm.ru

Kotsoev Konstantin Igorevich, Engineer

E-mail: kotsoev@kvantprogramm.ru