

МЕТОДЫ ОБНАРУЖЕНИЯ НЕИСПРАВНОСТЕЙ ОБОРУДОВАНИЯ АЭС

Ю.Д. Кацер, В.О. Козицин, И.В. Максимов*

Сколковский институт науки и технологий

121205, Москва, Территория инновационного центра «Сколково»,

Большой бульвар, д. 30, стр. 1

** ООО «КВАНТ ПРОГРАММ»*

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



Повышение требований к надежности и экономической эффективности работы АЭС ведет к росту востребованности современных решений основных задач диагностирования неисправностей оборудования: обнаружения, локализации, определения причин и прогнозирования развития неисправностей. Современные решения на основании статистического анализа, методов машинного обучения, интеллектуальной обработки сигналов и других успешно внедрены во многих отраслях промышленности, где доказали свою эффективность, сокращая расходы на ремонт и обслуживание оборудования.

Проведен анализ методов, применяемых для решения задач обнаружения неисправностей и отклонений в работе оборудования АЭС. Приводится классификация и сравнение наиболее распространенных методов обнаружения неисправности, дается описание, приводятся преимущества и недостатки методов и требования к входным данным.

Результатом работы является обобщение методов обнаружения, позволяющее упростить их выбор для решения конкретной задачи. Приведен обзор источников литературы, даны ссылки на работы с теоретическим описанием методов и примерами промышленного применения.

Ключевые слова: обнаружение неисправностей, АЭС, углубленная аналитика, диагностика, анализ данных.

ВВЕДЕНИЕ

Современные АЭС накапливают большие объемы неструктурированных данных. Технические средства позволяют организовать сбор и хранение данных, генерируемых различными источниками, к которым относятся прямые и косвенные измерения рабочих параметров технологических процессов, сигналы локальных систем контроля и диагностирования, данные лабораторных исследований, ручные измерения [1, 2]. Эти источники данных содержат потенциальную информацию о функционировании практически всего основного оборудования и всех важных технологических процессов АЭС. Анализируя показатели и данные, связанные с эксплуатацией оборудования, можно прогнозировать сроки изменения состояния и появления аномалий в работе. Это позволяет переходить к стратегии «обслуживание по состоянию», при которой сокращаются затраты на обслуживание оборудования, оптимизируются сроки и длительность планово-предупредительных ремонтов и минимизируется количество вмешательств ремонт-

© Ю.Д. Кацер, В.О. Козицин, И.В. Максимов, 2019

ного персонала в техническую систему, что приводит к уменьшению вероятности отказов. Сокращение затрат происходит за счет отказа от обслуживания оборудования, находящегося в работоспособном состоянии, остаточного ресурса которого хватит до следующего планово-предупредительного ремонта [3].

Персонал АЭС перегружен данными, но ему не хватает информации, необходимой для улучшения качества эксплуатации и технического обслуживания. Получать полезную диагностическую информацию из данных можно с помощью современных аналитических методов [4]. Они используются для углубленного понимания технологических процессов, раннего обнаружения неисправностей, прогнозирования состояния оборудования и выработки рекомендаций [5]. Методы, используемые при анализе, включают в себя алгоритмы машинного обучения, в том числе нейронные сети, распознавание образов, прогнозирование временных рядов, визуализацию, кластерный анализ, многомерные статистические методы, анализ графов, моделирование физических процессов и другие методы интеллектуального анализа данных. Их многообразие отображено в обзорах [6 – 14].

Полный цикл диагностирования оборудования описан в ГОСТ [15], схема цикла представлена на рис. 1.



Рис. 1. Схема цикла диагностирования оборудования

Штриховая линия на схеме обозначает необязательность использования предварительно обработанных данных в алгоритмах, решающих задачи локализации, определения причин и прогнозирования развития неисправностей; им на вход могут подаваться только выходные данные предыдущего этапа.



Рис. 2: Классификация методов обнаружения неисправностей

В работе рассматривается этап «Обнаружение неисправности». Задача обнаружения неисправностей является частным случаем задачи обнаружения аномалий в данных, подробное исследование которой приведено в фундаментальной работе [16]. Авторская классификация методов обнаружения неисправностей, являющаяся обобщением многих работ, приведена на рис. 2.

Существуют три подхода к обнаружению неисправностей: на базе физической модели оборудования, без использования физической модели и гибридный подход. Под физической моделью понимается математическое моделирование объекта диагностирования с помощью уравнений, описывающих физику происходящих в системе процессов. Физическое моделирование является предпочтительным для любой задачи диагностирования благодаря точности и интерпретируемости результата. Основным недостатком является сложность создания доброкачественной модели оборудования. Гибридные модели создаются для использования сильных сторон разных подходов. Построение таких моделей происходит следующим образом: моделируются основные компоненты системы, модель уточняется с помощью методов интеллектуального анализа, например, методов машинного обучения.

Наиболее распространённым способом обнаружения неисправностей на основе физических и гибридных моделей является сравнение выходных параметров модели и объекта диагностирования. Полученные при сравнении разности могут анализироваться описанными в данной работе методами. Методы, основанные на построении физической модели, и гибридные методы не затронуты в текущем обзоре, познакомиться с ними в применении к АЭС можно в обзорах [9, 17]. Смысл подходов к обнаружению неисправностей с использованием физической и гибридной моделей не столько в этапе анализа расхождений, сколько в построении качественных полных и адекватных моделей оборудования, позволяющих генерировать диагностические признаки.

СТАТИСТИЧЕСКИЕ КРИТЕРИИ ОБНАРУЖЕНИЯ (ПРОВЕРКА ГИПОТЕЗ)

Под проверкой гипотез понимается широкий класс практических задач математической статистики, используемый для углубленной аналитики данных. В процессе решения задач выдвигаются различные предположения (гипотезы), которые подтверждаются или отвергаются на основании полученных данных. Статистическими гипотезами могут являться любые предположения о свойствах временных рядов, например, постоянство среднего значения сигнала на всем интервале нормального режима работы оборудования [18]. В рамках данной теории были разработаны критерий Неймана-Пирсона [18], теория последовательного обнаружения Вальда [19] и другие, успешно применяемые для задач диагностирования АЭС [20 – 22]. Полное многообразие критериев и подробное описание теории проверки статистических гипотез представлено в фундаментальной работе [23] и в приведенных в работе источниках.

Статистические критерии обнаружения аномалий, многообразие которых подробно описано в [24], основаны на проверке статистических гипотез. Нормальный режим работы, являющийся эталоном, как правило, представлен в качестве архивной выборки, характеризующей безаварийный режим работы оборудования. Для заданного уровня достоверности вычисляются контрольные пределы, превышение которых означает отклонение значений анализируемого периода от эталонного, и, соответственно, может означать факт обнаружения отклонения состояния оборудования от нормального [25].

Статистические критерии делятся на одномерные и многомерные. Одномерные позволяют учитывать только один временной ряд (сигнал, признак) без учета остальных, что применимо, например, для обнаружения неисправностей в результате анализа полученных предварительно диагностических признаков. Многомерные учитывают множество временных рядов, их взаимное влияние и зависимости, что позволяет эффективнее на-

ходить неисправности в системах с множеством сигналов.

T^2 -критерий (критерий Хотеллинга), Q -критерий (квадратическая ошибка прогноза)

Существуют различные алгоритмы обнаружения аномалий на основе статистического критерия Хотеллинга [24, 26].

Критерий Хотеллинга показывает отклонение состояния оборудования в каждый момент времени по сравнению с предварительно полученным векторным эталоном. Каждое значение критерия характеризует отклонение состояния контролируемого оборудования от нормального.

При наличии ряда экспериментов, проведенных для одной единицы оборудования при схожих условиях, можно найти усредненные по экспериментам эталонные значения параметров, с которыми можно сравнивать усредненные значения будущих экспериментов.

Можно сравнивать текущие значения контролируемых параметров не с эталонными, посчитанными предварительно, а с аварийными значениями, например, предельно допустимая мощность, давление, соответствующее началу кипения теплоносителя и т.д. Тогда в нормальном состоянии значения критерия будут большими, а при приближении текущего состояния к аварийному значения станут стремиться к нулю.

Зачастую критерий Хотеллинга применяется совместно с методом главных компонент: для подпространства главных компонент (подпространства признаков с наибольшей дисперсией) вычисляется T^2 -критерий, а для подпространства оставшихся (подпространство разностей) применяется Q -критерий [27 – 29], значение которого равно евклидовой норме вектора в подпространстве разностей. Так как Q -критерий применяется к подпространству разностей, он позволяет обнаружить отклонение зависимостей между измеряемыми параметрами, не учтенное при получении главных компонент для тестовой выборки. Появление возмущений в Q -критерии говорит о нарушении зависимостей, что позволяет предполагать возникновение неисправности. Поскольку в подпространстве главных компонент содержатся сигналы с наибольшей дисперсией, а в подпространстве оставшихся компонент – в основном, шум, то контрольные пределы для T^2 -критерия часто превышают соответствующие пределы в подпространстве оставшихся компонент. По этой причине требуется гораздо более высокая амплитуда возмущений, вносимая неисправностью, для обнаружения ее с помощью T^2 -критерия.

T^2 -критерий и Q -критерий применяются совместно для лучшего качества обнаружения неисправности. Они позволяют выявить развитие аномалии на раннем этапе, однако Q -критерий является чувствительным к изменению зависимостей между контролируемыми параметрами, а T^2 -критерий зависит от используемой эталонной выборки, вид которой сказывается на работе алгоритма. Отдельной задачей является выбор контрольных пределов.

На основе T^2 -критерия и Q -критерия создаются более чувствительные индикаторы с помощью байесовского информационного критерия [30], уточнения с помощью выделения групп признаков с минимальным разбросом, максимальной значимостью и т.п. [31].

Для понижения размерностей и преобразования признаков в статистических критериях обнаружения кроме метода главных компонент могут использоваться нейронные сети, например, автокодировщик [32, 33].

Кумулятивная сумма

Кумулятивная сумма (CUSUM – CUmulative SUM) используется для обнаружения отклонения от нормального состояния [34, 35]. Этот критерий использует своего рода «память» для фиксации последовательных отклонений от среднего с некоторой зоной нечувствительности и их дальнейшего суммирования. В случае, когда кумулятивная сумма этих отклонений превышает заданный порог, формируется сигнал тревоги. Большое количество модификаций CUSUM применяются в различных областях науки и техники [36 – 41].

Экспоненциально взвешенное скользящее среднее

Экспоненциально взвешенное скользящее среднее (EWMA – Exponentially Weighted Moving Average) используется для мониторинга отклонения от нормального состояния [24, 42, 43]. Этот критерий отслеживает экспоненциально взвешенное скользящее среднее всех предшествующих выборочных средних, т.е. взвешивает выборки в экспоненциально убывающем порядке так, что самые последние выборки взвешиваются наиболее высоко, в то время как самые отдаленные выборки влияют очень слабо. Существуют различные модификации критерия EWMA [44 – 47].

Перечисленные статистические критерии имеют широкое применение во многих промышленных системах и являются качественными показателями возникновения аномалий. CUSUM и EWMA особенно чувствительны и могут работать как с одномерными, так и многомерными данными. T^2 -критерий применяется только для многомерных временных рядов. Среди минусов данных критериев в их классической реализации – обязательное определение первых двух статистических моментов для безаварийного режима работы контролируемого оборудования, а также необходимость выбора контрольных границ.

Поиск точек изменения свойств временных рядов

Данный метод предполагает поиск точек, в которых произошли изменения статистических характеристик сигналов, выборок данных или временных рядов. В методе могут использоваться разные алгоритмы поиска и различные статистические характеристики сигналов – метрики. С подробным описанием задачи и основными алгоритмами можно ознакомиться в книге [48], а в применении к некоторым специфическим областям знаний – в [49]. Для некоторых алгоритмов в качестве входных данных требуются стационарные либо независимые временные ряды с одинаковым распределением вероятностей. Во всех работах, посвященных этому методу обнаружения отклонений, используется четкое разделение на онлайн- [23, 48, 50] и оффлайн- [23, 51, 52] алгоритмы.

Метод обнаружения отклонений на основе поиска точек изменения свойств временных рядов применяется и в технических системах [53 – 55].

К недостаткам метода относятся вычислительная сложность моделей и наличие ограничений на исходные данные, к достоинствам – интерпретируемость и ясность результатов, оптимальное решение для задач оффлайн-обнаружения, большая вариативность моделей и метрик.

КРИТЕРИИ ОБНАРУЖЕНИЯ НА ОСНОВЕ СТАТИСТИЧЕСКОГО МОДЕЛИРОВАНИЯ

Метод оценки многомерных состояний (MSET – Multivariate State Estimation Technique)

Этот метод основан на нахождении зависимостей между признаками (сигналами) по эталонным данным, полученным предварительно [56]. Из эталонных данных изначально выбираются наиболее значимые точки (состояния). На основании полученных зависимостей вычисляются точки модели, описывающие каждую точку выборки. Для полученных разностей применяются статистические критерии обнаружения. Метод привлекателен проприетарным набором нелинейных операторов, используемым для расчета весов, необходимых при переводе входных данных в подпространство признаков. Оптимизация работы алгоритма за счет использования регуляризации описана в [57].

Недостатком метода считается необходимость лицензирования у Аргоннской национальной лаборатории (США) для использования полноценного алгоритма с проприетарным набором нелинейных операторов. Кроме того система чувствительна к качеству входных данных.

Методы обнаружения неисправностей на основе прогнозирования сигналов

Обнаружение неисправностей на основе моделей прогнозирования происходит в два этапа:

- строится прогноз сигналов с помощью предсказательных моделей, обученных на исторических данных;

- прогноз сравнивается с действительными значениями сигнала.

Можно находить вектор разностей, на котором применяются статистические критерии обнаружения отклонений (T^2 , Q , CUSUM, EWMA) [58]. Можно устанавливать ограничения на разладку прогноза и действительных значений, например, полученную как среднеквадратичную ошибку; для модели прогнозирования на основе LSTM-сетей (Long Short-Term Memory – долгая краткосрочная память) подобный алгоритм описан в [59].

Для прогнозирования используются два типа моделей:

- регрессионные, к которым относятся линейная, полиномиальная, метод опорных векторов (Support Vector Regression), случайный лес (Random Forest Regression), градиентный бустинг (Gradient Boosting Regression), нейронные сети и ряд других, рассмотренные в [4, 60];

- авторегрессионные – ARIMA (Autoregressive Integrated Moving Average) [61], VAR (Vector Autoregression) [61], Хольта-Уинтерса (модель экспоненциального сглаживания третьего порядка) [62, 63], LSTM [64, 65].

Многие из перечисленных моделей сложны в настройке и требовательны к вычислительным мощностям. Преимуществами же их являются точность, интерпретируемость результатов, возможность находить и использовать сложные взаимосвязи в данных.

Методы обнаружения неисправностей на основе классификации состояний

В последнее время методы машинного обучения, в частности, классификации, привели к значительным успехам в диагностировании неисправностей оборудования. Обнаружение отклонений на основе классификации происходит с помощью обученной на данных о нормальном и всех аномальных режимах работы модели, которая при работе классифицирует режимы оборудования, относя каждое состояние к какому-либо классу. К основным моделям классификации [66] можно отнести логистическую регрессию, наивный байесовский классификатор, метод опорных векторов, метод ближайших соседей, деревья решений, градиентный бустинг, нейронные сети [4, 60, 67]. Модели классификации получили широкое распространение в задачах диагностирования каналов измерений, электродвигателей, редукторов, насосов, компрессоров и других.

Классификационные модели обеспечивают лучшую адаптивность к сложным системам и позволяют распознавать различные типы неисправности, разделяя их, что упрощает процедуры локализации и определения причин возникновения отклонений. Однако для построения моделей необходим большой объем исторических данных, содержащих как режимы безотказной работы, так и режимы с неисправностями, причем обнаружение будет возможно только для тех неисправностей, данные о которых использовались в процессе обучения моделей.

Кластерный анализ

Этот анализ может применяться для предварительной обработки сигналов, например, для группировки сигналов, имеющих схожие параметры [68], или для разметки данных с целью улучшения качества работы методов обнаружения [69]. Для поиска отклонений от нормального режима кластерный анализ применяется к временным рядам с целью выделения режимов работы оборудования [70].

К наиболее распространенным алгоритмам кластеризации можно отнести EM-алгоритм (оценки максимального правдоподобия параметров вероятностных моделей); K-средних; метод нечеткой кластеризации C-средних; иерархические и агломеративные алгоритмы; спектральную кластеризацию; пространственную кластеризацию, ос-

нованную на плотности. Подробное описание перечисленных алгоритмов можно найти в [4, 60, 71], примеры их применения для различных задач в технических системах приведены в [72 – 77].

В качестве исходных данных для алгоритмов кластеризации могут быть использованы как исходные сигналы, так и выделенные из них диагностические признаки; кроме того, в общем случае требований к входным данным у алгоритмов кластеризации нет, что является одним из достоинств этого метода. Недостатком можно назвать использование эвристик в большинстве методов кластеризации на различных этапах решения задачи.

Изолирующий лес

Изолирующий лес (Isolation Forest, iForest) [78] обнаруживает аномалии в данных, основываясь на предположении, что аномальные значения имеют низкую глубину в построенных деревьях. Таким образом, обнаружение происходит не за счет выделения нормального режима и дальнейшего поиска отклонений от него, как работают многие методы, а за счет изолирования отдельных значений выборки с помощью случайного леса [79]. Метод эффективен для задач онлайн-обнаружения неисправностей в сложных системах с большим количеством сигналов, что продемонстрировано в работах [80 – 83]. Модификация вышеописанного оригинального алгоритма и сравнение с ним представлены в работе [84].

Изолирующий лес применяется также в качестве инструмента отбора репрезентативных признаков из числа исходных [85].

Преимуществом метода является невысокая вычислительная сложность и возможность работать с разнородными данными на входе. Недостатком является отсутствие возможности работы с данными как с временным рядом, – они воспринимаются как набор состояний.

Одноклассовый классификатор на основе метода опорных векторов

Метод описания данных опорными векторами (Support Vector Domain Description, SVDD) [86] или одноклассовый классификатор метода опорных векторов служит для обнаружения выбросов, аномалий или новизны в данных [87 – 89]. Разделяющая сферическая граница строится вокруг данных набором опорных векторов так, чтобы максимальное количество данных было внутри сферы минимального радиуса. Возможно использование ядер, например, гауссовского (Radial Basis Function, RBF) или полиномиального, которые переводят данные в новое функциональное пространство большей размерности, тем самым делая алгоритм более гибким и точным [90]. Этот алгоритм может применяться для обнаружения отклонений в работе оборудования по показаниям датчиков вибрации [91]. В работе [92] исследовалось применение отдельно обученных SVM-модулей для диагностирования неисправности на уровне компонентов атомной станции, интегрированных в единую интеллектуальную систему. Недостатком алгоритма является вычислительная сложность. В связи с этим существует большое количество модификаций, которые снижают вычислительную нагрузку, делая возможным использование метода в онлайн-режиме [93 – 97]. Наиболее популярные модификации:

- L-SVM с регуляризационным членом LogDet [98];
- Incremental Covariance-guided One-Class Support Vector Machine (iCOSVM) [99].

Байесовские сети

Байесовская сеть [100, 101] – направленный ациклический граф, вершины которого – переменные, а ребра соответствуют вероятностным отношениям, определяющим непосредственные зависимости. Метод применяется для поиска неисправностей как самостоятельно [102, 103], так и в комплексе с другими алгоритмами [103, 104]. Байесовские сети, которые используют переменные смежных временных шагов, называют динамическими байесовскими сетями. Они также используются для поиска неисправно-

стей и аномалий в работе оборудования [105, 106].

Скрытые марковские модели

Такие модели сводятся к поиску наиболее вероятной модели марковского процесса путем нахождения скрытых состояний, количество и взаимные связи которых заранее неизвестны [101]. Скрытая марковская модель, являющаяся частным случаем байесовской сети, отличается тем, что не учитывает причинно-следственные связи. Задача обнаружения сводится к поиску скрытого образа неисправности [107 – 109]. Марковские модели хорошо зарекомендовали себя в поиске и оценке неисправностей на основе моделирования нестационарных сигналов, например, вибрации [110].

Пример совместной работы скрытой марковской модели, использовавшейся для поиска неисправности, и байесовской сети, применявшейся для установления причины неисправности, приведен в работе [111]. Недостатком этих моделей является вычислительная сложность.

КРИТЕРИИ ОБНАРУЖЕНИЯ НА ОСНОВЕ ЭКСПЕРТНЫХ ЗНАНИЙ

Нечеткая логика

Алгоритмы на основе нечеткой логики [112] широко применяются для оценки состояния оборудования и поиска неисправностей на атомных станциях [113] и в других технических системах [114 – 116]. Нечеткая логика легла также в основу разных экспертных систем, используемых для поиска аномалий в работе оборудования [117, 118]. Другим применением алгоритмов на основе нечеткой логики является поиск неисправных датчиков [119].

Наиболее известными алгоритмами с использованием нечеткой логики для поиска неисправностей являются

- FLDM (Fuzzy Logic Diagnostic Monitoring) [120];
- FLARS (Fuzzy Logic Algorithm for Recognition Signal) [121];
- ANFIS (Adaptive-Network-Based Fuzzy Inference System) [122];
- TSK (Takagi-Sugeno-Kang type fuzzy logic system) [123];
- FMEA (Failure Mode and Effects Analysis) [124];
- C-means (алгоритм нечеткой самоорганизации) [73, 75];
- GFS (Genetic Fuzzy Systems) [125].

В настоящее время все большую популярность для поиска неисправностей набирают «мягкие вычисления» (Soft Computing) [126]. Их смысл в комбинации таких алгоритмов, как нечеткая логика, искусственные нейронные сети, вероятностные рассуждения и генетические алгоритмы. Существует большое количество и других алгоритмов, которые в комбинации с нечеткой логикой также успешно применяются для поиска неисправностей [127–129].

К достоинствам алгоритмов на основе нечеткой логики относят возможность моделирования сложных систем, поскольку они не требуют конкретной модели. Эти алгоритмы устойчивы к незначительным изменениям. С другой стороны, часто возникают трудности с разработкой нечетких правил и функций, а также с интерпретацией результатов.

Режимная диагностика (дерева неисправностей)

Анализ дерева неисправностей – это методика выявления и анализа факторов, которые могут способствовать возникновению конкретного нежелательного события (называемого «конечное событие») [1]. Причинные факторы определяют дедуктивным образом, организуют логически и представляют наглядно с помощью древовидной схемы, изображающей логическую взаимосвязь причинных факторов с конечным событием.

Факторы, указанные в дереве, могут быть событиями, связанными с пересечением диагностического порога, отказом элемента технических средств или любыми другими

событиями, которые приводят к нежелательному событию. В этом методе выполняется процедура поиска диагноза или процесс перехода от одного узла к другому, производимый по текущим измерениям в соответствии с развитием аномалии. С другой стороны, при обнаружении аномалии по подобным деревьям возможно определить и сделать анализ корневой причины неисправности, двигаясь по дереву в обратном направлении.

К достоинствам можно отнести высокую степень интерпретируемости алгоритма, а также выход на конкретные диагнозы. Метод представляет строгий высокосистематизированный и гибкий подход, позволяющий анализировать разнообразные факторы в сложных технических системах.

ЗАКЛЮЧЕНИЕ

В обзоре приведены основные методы, используемые для обнаружения неисправностей оборудования АЭС (табл. 1), их достоинства и недостатки. Активное развитие и совершенствование алгоритмов интеллектуальной обработки данных позволяет постоянно улучшать качество диагностирования сложных технических систем, что увеличивает их экономическую эффективность и надежность.

Таблица 1

Основные характеристики методов обнаружения

№	Метод	Ограничения для входных данных	Данные о неисправностях	Одном./многом. данные	Online /offline
Статистические критерии обнаружения					
1	T^2 -критерий	Нормализация	Безаварийный режим работы	-/+	+/+
2	Q-критерий	Нормализация	Безаварийный режим работы	-/+	+/+
3	CUSUM	Нормализация	Безаварийный режим работы	+/+	+/+
4	EWMA	Нормализация, равноотстоящие	Безаварийный режим работы	+/+	+/+
5	Поиск точек изменения свойств временных рядов	Нормализация, равноотстоящие*	–	+/+*	+*/+*
Критерии обнаружения на основе статистического моделирования					
6	MSET	Нормализация	Безаварийный режим работы	-/+	+/+
7	Обнаружение на основе прогнозирования	Нормализация, стационарность*, равноотстоящие	Безаварийный режим работы	+/+*	+/+
8	Классификация	Нормализация, равноотстоящие	Данные обо всех возможных неисправностях	+/+	+/+
9	Кластерный анализ	Равноотстоящие*	–	+/+	+/+
10	One-class SVM	Нормализация	–	+/+	+/+
11	Изолирующий лес	Нормализация	–	+/+	-/+
12	Байесовские сети	–*	–	+/+	+/+
13	Скрытые марковские модели	–*	–	+/+	+/+
Критерии обнаружения на основе экспертных знаний					
14	Нечеткая логика	–	Данные обо всех возможных неисправностях*	+/+	+/+
15	Режимная диагностика	–	Данные обо всех возможных неисправностях	+/+	+/+

* – распространяется не на все модели, используемые в методе

Некоторые методы обнаружения неисправностей оборудования подразумевают процесс контролируемого обучения (обучение с учителем). Они основаны на примерах сигналов, помеченных соответствующими известными классами состояний (нормальных и аномальных). На практике сигналы, собранные за время работы оборудования, чаще всего не имеют метки, т.е. информация о соответствующем типе неисправности недоступна или доступна для ограниченного временного интервала. Часто единственной информацией о данных является безаварийный режим работы, для которого они были собраны. По этим причинам важно классифицировать методы на те, которым требуется информация обо всех возможных неисправностях и путях их развития (методы многоклассовой классификации, нечеткой логики и режимная диагностика), методы, которым требуется информация о нормальном (безаварийном) режиме работы (T^2 , Q , CUSUM, EWMA, MSET и методы обнаружения на основе прогнозирования) и не требующие никакой информации (поиск точек изменения свойств временных рядов, One-class SVM, изолирующий лес, байесовские сети и скрытые марковские модели). Стоит также отметить, что скорость протекания переходных процессов и развития неисправности в значительной степени влияют на время обнаружения отклонения от нормального состояния. Чем динамичнее развивается процесс, тем быстрее происходит обнаружение. При медленном и незначительном протекании процесса алгоритмы обнаружения могут адаптироваться к новым данным и пропустить неисправность.

Важным этапом перед применением описанных методов является предварительная обработка данных, позволяющая улучшить качество обнаружения неисправностей, упростить процедуры настройки методов, избавиться от шума, сократить размерность анализируемого пространства, чтобы уменьшить требования алгоритмов к вычислительным ресурсам.

Литература

1. Аркадов Г.В., Павелко В.И., Финкель Б.М. Системы диагностирования ВВЭР. – М.: Энергоатомиздат, 2010. – 391 с.
2. Аркадов Г.В., Егоров С.В., Кацер Ю.Д. и др. Предиктивная аналитика и диагностика АЭС. – М.: Диапром, 2019. – 72 с.
3. Advanced Surveillance, Diagnostic and Prognostic Techniques in Monitoring Structures, Systems and Components in Nuclear Power Plants. Nuclear Energy Series no. NP-T-3.14. – Vienna: INTERNATIONAL ATOMIC ENERGY AGENCY, 2013. Электронный ресурс: <https://www.iaea.org/publications/8763/advanced-surveillance-diagnostic-and-prognostic-techniques-in-monitoring-structures-systems-and-components-in-nuclear-power-plants> (дата доступа: 20.07.2019).
4. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning. – Springer New York, 2009. – 745 p.
5. Chiang L. H., Russell E. L., Braatz R. D. Fault Detection and Diagnosis in Industrial Systems. – Springer London, 2001. – 279 p.
6. Venkatasubramanian V., Rengaswamy R., Kavuri S. N. A review of process fault detection and diagnosis // Computers & Chemical Engineering. – 2003. – Vol. 27. – No. 3. – PP. 313-326.
7. Venkatasubramanian V., Raghunathan R., Kavuri S. N. et al. A review of process fault detection and diagnosis: Part III: Process history based methods // Computers & chemical engineering. – 2003. – Vol. 27. – No. 3. – PP. 327-346.
8. Qin S. J. Data-driven Fault Detection and Diagnosis for Complex Industrial Processes // IFAC Proceedings Volumes. – 2009. – Vol. 42. – No. 8. – PP. 1115-1125.
9. Ma J., Jiang J. Applications of fault detection and diagnosis methods in nuclear power plants: A review // Progress in Nuclear Energy. – 2011. – Vol. 53. – No. 3. – PP. 255-266.
10. Si Xiao-Sheng, Wang Wenbin, Hu Chang-Hua et al. Remaining useful life estimation – A review on the statistical data driven approaches // European Journal of Operational Research. – 2011. – Vol. 213. – No. 1. – PP. 1-14.

11. *An Dawn, Choi Joo Ho, Kim Nam Ho*. Options for Prognostics Methods: A review of data-driven and physics-based prognostics. / Proc. of the 54-th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference. – American Institute of Aeronautics and Astronautics, 2013.
12. *Dai Xuewu, Gao Zhiwei*. From Model, Signal to Knowledge: A Data-Driven Perspective of Fault Detection and Diagnosis // IEEE Transactions on Industrial Informatics. – 2013. – Vol. 9. – No. 4. – PP. 2226-2238.
13. *Aminikhanghahi S., Cook D. J.* A survey of methods for time series change point detection // Knowledge and Information Systems. – 2016. – Vol. 51. – No. 2. – PP. 339-367.
14. *Patel Himanshukumar R, Shah Vipul A*. Fault Detection and Diagnosis Methods in Power Generation Plants-The Indian Power Generation Sector Perspective: An Introductory Review / PDP Journal of Energy and Management. – 2018. – Vol. 2. – No. 2. – PP. 31-49.
15. ГОСТ Р ИСО 13381-1 – 2016. Контроль состояния и диагностика машин. Прогнозирование технического состояния. Часть 1. Общее руководство. – М.: Стандартинформ, 2017. – 24 с.
16. *Chandola V., Banerjee A., Kumar V*. Anomaly detection // ACM Computing Surveys. – 2009. – Vol. 41. – No. 3. – PP. 1-58.
17. *Ayo-Imoru R.M., Cilliers A.C*. A survey of the state of condition-based maintenance (CBM) in the nuclear power industry // Annals of Nuclear Energy. – 2018. – Vol. 112. – PP. 177-188.
18. *Ивановский П. И.* Теория вероятностей и математическая статистика. Основы, прикладные аспекты с примерами и задачами в среде MathCad. – БХВ-Петербург, 2008. – 528 с.
19. *Wald A*. Sequential analysis. – Courier Corporation, 1973. – 213 p.
20. *Hines J. W., Garvey D*. Development and Application of Fault Detectability Performance Metrics for Instrument Calibration Verification and Anomaly Detection // Journal of Pattern Recognition Research. – 2006. – Vol. 1. – No. 1. – PP. 2-15.
21. *Xin Jin, Yin Guo, Soumik Sarkar et al*. Anomaly Detection in Nuclear Power Plants via Symbolic Dynamic Filtering // IEEE Transactions on Nuclear Science. – 2011. – Vol. 58. – No. 1. – PP. 277-288.
22. *Di Maio F., Baraldi P., Zio E. et al*. Fault Detection in Nuclear Power Plants Components by a Combination of Statistical Methods // IEEE Transactions on Reliability. – 2013. – Vol. 62. – No. 4. – PP. 833-845.
23. *Tartakovsky A., Nikiforov I., Basseville M*. Sequential analysis: Hypothesis testing and changepoint detection. – Chapman and Hall/CRC, 2014. – 575 p.
24. *Montgomery D. C*. Introduction to statistical quality control. – John Wiley & Sons, 2007. – 752 p.
25. ГОСТ Р ИСО 7870-1-2011 Статистические методы. Контрольные карты. Часть 1. Общие принципы. ИСО 7870-1-2011. – М.: Стандартинформ, 2011. – 16 с.
26. *Qin S. J*. Statistical process monitoring: basics and beyond // Journal of Chemometrics. – 2003. – Vol. 17. – No. 8-9. – PP. 480-502.
27. *Mujica L.E., Rodellar J., Fernandez A. et al*. Q-statistic and T²-statistic PCA-based measures for damage assessment in structures // Structural Health Monitoring: An International Journal. – 2010. – Vol. 10. – No. 5. – PP. 539-553.
28. *Zhao C., Gao F*. Online fault prognosis with relative deviation analysis and vector autoregressive modeling // Chemical Engineering Science. – 2015. – Vol. 138. – PP. 531-543.
29. *Li Wei, Peng Minjun, Wang Qingzhong*. False alarm reducing in PCA method for sensor fault detection in a nuclear power plant // Annals of Nuclear Energy. – 2018. – Vol. 118. – PP. 131-139.
30. *Ge Zhiqiang, Zhang Muguang, Song Zhihuan*. Nonlinear process monitoring based on linear subspace and Bayesian inference // Journal of Process Control. – 2010. – Vol. 20. – No. 5. – PP. 676-688.
31. *Xu Chen, Zhao Shunyi, Liu Fei*. Distributed plant-wide process monitoring based on PCA with minimal redundancy maximal relevance // Chemometrics and Intelligent Laboratory Systems. – 2017. – Vol. 169. – PP. 53-63.
32. *Yang Hsu-Hao, Huang Mei-Ling, Yang Shih-Wei*. Integrating Auto-Associative Neural Networks with Hotelling T² Control Charts for Wind Turbine Fault Detection // Energies. – 2015. – Vol. 8. – No. 10. – PP. 12100-12115.
33. *Hongjun Xiao, Daoping Huang, Yongping Pan et al*. Fault diagnosis and prognosis of

- wastewater processes with incomplete data by the auto-associative neural networks and ARMA model // *Chemometrics and Intelligent Laboratory Systems*. – 2017. – Vol. 161. – PP. 96-107.
34. *Encyclopedia of Mass Spectrometry*. – Elsevier, 2015. Электронный ресурс: https://www.ebook.de/de/product/24358562/encyclopedia_of_mass_spectrometry.html (дата доступа: 20.07.2019).
35. *Ferrer-Riquelme A.J.* Statistical Control of Measures and Processes // *Comprehensive Chemometrics*. – Elsevier, 2009. – PP. 97-126.
36. *Lucas J.M., Crosier R.B.* Fast Initial Response for CUSUM Quality-Control Schemes: Give Your CUSUM A Head Start // *Technometrics*. – 1982. – Vol. 24. – No. 3. – PP. 199-205.
37. *Paul W.L., Barnett N.S.* Control charting instrumental analyses // *Laboratory Automation & Information Management*. – 1995. – Vol. 31. – No. 2. – PP. 141-148.
38. *Simpson J.R., Keats J.B.* Sensitivity study of the CUSUM control chart with an economic model // *International Journal of Production Economics*. – 1995. – Vol. 40. – No. 1. – PP. 1-19.
39. *Wu Chunjie, Yu Miaomiao, Zhuang Fang.* Properties and enhancements of robust likelihood CUSUM control chart // *Computers & Industrial Engineering*. – 2017. – Vol. 114. – PP. 80-100.
40. *Fortea-Sanchis C., Escrig-Sos J.* Quality Control Techniques in Surgery: Application of Cumulative Sum (CUSUM) Charts // *Cirugia Espanola (English Edition)*. – 2019. – Vol. 97. – No. 2. – PP. 65-70.
41. *Bodnar O., Schmid W.* CUSUM charts for monitoring the mean of a multivariate Gaussian process // *Journal of Statistical Planning and Inference*. – 2011. – Vol. 141. – No. 6. – PP. 2055-2070.
42. *Ferrer-Riquelme A.J.* Statistical Control of Measures and Processes // *Comprehensive Chemometrics*. – Elsevier, 2009. – PP. 97-126.
43. *Tobias P.A.* Statistical Process Control and Failure Mode Analysis // *Encyclopedia of Materials: Science and Technology*. – Elsevier, 2001. – PP. 8816-8824.
44. *Sevil Senturk, Nihal Erginel, Ihsan Kaya, Cengiz Kahraman.* Fuzzy exponentially weighted moving average control chart for univariate data with a real case application // *Applied Soft Computing*. – 2014. – Vol. 22. – PP. 1-10.
45. *Haq Abdul, Khoo Michael B.C.* An adaptive multivariate EWMA chart // *Computers & Industrial Engineering*. – 2019. – Vol. 127. – PP. 549-557.
46. *Haq Abdul, Khoo Michael B.C.* New adaptive EWMA control charts for monitoring univariate and multivariate coefficient of variation // *Computers & Industrial Engineering*. – 2019. – Vol. 131. – PP. 28-40.
47. *Park Jangho, Jun Chi-Hyuck.* A new multivariate EWMA control chart via multiple testing // *Journal of Process Control*. – 2015. – Vol. 26. – PP. 51-55.
48. *Brodsky B.E, Darkhovsky B.S.* Nonparametric methods in change point problems. – Springer Science & Business Media, 2013. – 210 p.
49. *Chen Jie, Gupta Arjun K.* Parametric statistical change point analysis: with applications to genetics, medicine, and finance. – Springer Science & Business Media, 2011. – 273 p.
50. *Kawahara Y., Sugiyama M.* Sequential change-point detection based on direct density-ratio estimation // *Statistical Analysis and Data Mining*. – 2011. – Vol. 5. – No. 2. – PP. 114-127.
51. *Garreau D.* Change-point detection and kernel methods: Ph.D. thesis / PSL Research University. – 2017. – 144 p.
52. *Truong C., Oudre L., Vayatis N.* Selective review of offline change point detection methods. – 2019. Электронный ресурс: <https://arxiv.org/abs/1801.00718> (дата доступа: 23.07.2019).
53. *Lai Tze Leung.* Sequential Changepoint Detection in Quality Control and Dynamical Systems // *Journal of the Royal Statistical Society: Series B (Methodological)*. – 1995. – Vol. 57. – No. 4. – PP. 613-644.
54. *Marcos F.S.V. D'Angelo, Reinaldo M. Palhares, Ricardo H.C. Takahashi et al.* Incipient fault detection in induction machine stator-winding using a fuzzy-Bayesian change point detection approach // *Applied Soft Computing*. – 2011. – Vol. 11. – No. 1. – PP. 179-192.
55. *Niculita Octavian, Skaf Zakwan, Jennions Ian K.* The Application of Bayesian Change Point

- Detection in UAV Fuel Systems // Procedia CIRP. – 2014. – Vol. 22. – PP. 115-121.
56. *Zavaljevski N., Gross K. C.* Sensor fault detection in nuclear power plants using multivariate state estimation technique and support vector machines. / Proc. of the III-rd International Conference of the Yugoslav Nuclear Society YUNSC 2000. – 2000.
57. *Hines J Wesley, Usynin Alexander.* MSET performance optimization through regularization // Nuclear Engineering and Technology. – 2005. – Vol. 37. – No. 2. – PP. 177-184.
58. *Sanchez-Fernandez A., Baldan F.J., Sainz-Palmero G.I. et al.* Fault detection based on time series modeling and multivariate statistical process control // Chemometrics and Intelligent Laboratory Systems. – 2018. – Vol. 182. – PP. 57-69.
59. *Filonov P., Lavrentyev A., Vorontsov A.* Multivariate Industrial Time Series with Cyber-Attack Simulation: Fault Detection Using an LSTM-based Predictive Data Model // NIPS Time Series Workshop 2016, Barcelona, Spain. – 2016. Электронный ресурс: <https://arxiv.org/abs/1612.06676> (дата доступа: 20.07.2019).
60. *Bishop C. M.* Pattern Recognition and Machine Learning. – Springer-Verlag New York Inc., 2006. Электронный ресурс: https://www.ebook.de/de/product/5324937/christopher_m_bishop_pattern_recognition_and_machine_learning.html (дата доступа: 20.07.2019).
61. *Brockwell P. J., Davis R. A., Calder M. V.* Introduction to time series and forecasting. – Springer, 2002. – Vol. 2. – 434 p.
62. *Chatfield C.* The Holt-Winters Forecasting Procedure // Applied Statistics. – 1978. – Vol. 27. – No. 3. – P. 264.
63. *Tratar Liljana Ferbar, Strmcnik Ervin.* The comparison of Holt-Winters method and Multiple regression method: A case study // Energy. – 2016. – Vol. 109. – PP. 266-276.
64. *Gers F.A.* Learning to forget: continual prediction with LSTM / Proc. of the IX-th International Conference on Artificial Neural Networks: ICANN 99. – IEE, 1999.
65. *Klaus Greff, Rupesh K. Srivastava, Jan Koutnik et al.* LSTM: A Search Space Odyssey // IEEE Transactions on Neural Networks and Learning Systems. – 2017. – Vol. 28. – No. 10. – PP. 2222-2232.
66. ГОСТ Р ИСО 13379-1-2015. Контроль состояния и диагностика машин. Методы интерпретации данных и диагностирования. Общее руководство. Часть 1. – М.: Стандартинформ, 2015. – 34 с.
67. *Lu B., Upadhyaya B.R.* Monitoring and fault diagnosis of the steam generator system of a nuclear power plant using data-driven modeling and residual space analysis // Annals of Nuclear Energy. – 2005. – Vol. 32. – No. 9. – PP. 897-912.
68. *Guangrong L., Xiaohua H., Xiaojong S. et al.* A novel unsupervised feature selection method for bioinformatics data sets through feature clustering / Proc. of the 2008 IEEE International Conference on Granular Computing. – IEEE. – 2008. – PP. 41-47.
69. *Hajjem A., Bellavance F., Larocque D.* Mixed-effects random forest for clustered data // Journal of Statistical Computation and Simulation. – 2012. – Vol. 84. – No. 6. – PP. 1313-1328.
70. *Mohammad Hamed Ardakani, Ahmed Shokry, Gerard Escudero et al.* Unsupervised Automatic Updating of Classification Models of Fault Diagnosis for Novelty Detection // Computer Aided Chemical Engineering. – Elsevier, 2018. – PP. 1123-1128.
71. *Anderberg M.R.* Cluster analysis for applications: probability and mathematical statistics: a series of monographs and textbooks. – Academic press, 2014. – Vol. 19.
72. *Bengio Y., Gingras F., Goulard B. et al.* Gaussian mixture densities for classification of nuclear power plant data // Computers and artificial intelligence. – 1998. – Vol. 17. – No. 2-3. – PP. 189-209.
73. *Baraldi P., Razavi-Far R., Zio E.* Bagged ensemble of Fuzzy C-Means classifiers for nuclear transient identification // Annals of Nuclear Energy. – 2011. – Vol. 38. – No. 5. – PP. 1161-1171.
74. *Скоморохов А. О.* Многомерные статистические методы диагностики аномальных состояний ЯЭУ / Дис. д-ра. техн. наук: 05.14.03. – Обнинск, ИАТЭ НИЯУ МИФИ, 2011. – 302 с.
75. *Perasso A., Campi C., Toraci C. et al.* Application of Possibilistic C-Means for Fault Detection in Nuclear Power Plant Data // Journal of Engineering for Gas Turbines and Power. – 2014. – Vol. 137. – No. 6. – P. 062901.

76. *Kulkowski K., Grochowski M., Kobylarz A. et al.* Application of data driven methods in diagnostic of selected process faults of nuclear power plant steam turbine // Polish Control Conference / Springer. – 2017. – PP. 631-640.
77. *Wang Bing, Hu Xiong, Li Hongru.* Rolling bearing performance degradation condition recognition based on mathematical morphological fractal dimension and fuzzy C-means // Measurement. – 2017. – Vol. 109. – PP. 1-8.
78. *Liu Fei Tony, Ting Kai Ming, Zhou Zhi-Hua.* Isolation Forest / Proc. of the 2008 Eighth IEEE International Conference on Data Mining. – IEEE, 2008.
79. *Sun L., Versteeg S., Boztas S. et al.* Detecting Anomalous User Behavior Using an Extended Isolation Forest Algorithm: An Enterprise Case Study – 2016. Электронный ресурс: <https://arxiv.org/abs/1609.06676> (дата доступа: 20.07.2019).
80. *Tan Swee Chuan, Ting Kai Ming, Liu Tony Fei.* Fast anomaly detection for streaming data // Twenty-Second International Joint Conference on Artificial Intelligence. – 2011.
81. *Ding Zhiguo, Fei Minrui.* An Anomaly Detection Approach Based on Isolation Forest Algorithm for Streaming Data using Sliding Window // IFAC Proceedings Volumes. – 2013. – Vol. 46. – No. 20. – PP. 12-17.
82. *Susto Gian Antonio, Beghi Alessandro, McLoone Sean.* Anomaly detection through on-line isolation Forest: An application to plasma etching / Proc. of the XXVIII-th Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC). – IEEE, 2017.
83. *Wei Mao, Xiu Cao, Qinhua Zhou et al.* Anomaly Detection for Power Consumption Data based on Isolated Forest / Proc. of the 2018 International Conference on Power System Technology (POWERCON). – IEEE, 2018.
84. *Sudipto Guha, Nina Mishra, Gourav Roy et al.* Robust random cut forest based anomaly detection on streams // International conference on machine learning. – 2016. – PP. 2712-2721.
85. *Wo-Ruo Chen, Yong-Huan Yun, Ming Wen et al.* Representative subset selection and outlier detection via isolation forest // Analytical Methods. – 2016. – Vol. 8. – No. 39. – PP. 7225-7231.
86. *Tax David M.J., Duin Robert P.W.* Support Vector Data Description // Machine Learning. – 2004. – Vol. 54. – No. 1. – PP. 45-66.
87. *Jooyoung Park, Daesung Kang, Jongho Kim et al.* SVDD-Based Pattern Denoising // Neural Computation. – 2007. – Vol. 19. – No. 7. – PP. 1919-1938.
88. *Chalapathy Raghavendra, Menon Aditya Krishna, Chawla Sanjay.* Anomaly detection using one-class neural networks / arXiv preprint. – 2018. Электронный ресурс: <https://arxiv.org/abs/1802.06360v2> (дата доступа: 20.07.2019).
89. *Yong Zhang, Xiao-Dan Liu, Fu-Ding Xie et al.* Fault classifier of rotating machinery based on weighted support vector data description // Expert Systems with Applications. – 2009. – Vol. 36. – No. 4. – PP. 7928-7932.
90. *Wang Xiaoming, lai Chung Fu, Wang Shitong.* Theoretical analysis for solution of support vector data description // Neural Networks. – 2011. – Vol. 24. – No. 4. – PP. 360-369.
91. *Tax D, Ypma A., Duin R.* Support vector data description applied to machine vibration analysis / Proc. of the V-th Annual Conference of the Advanced School for Computing and Imaging. – Citeseer. – 1999. – Vol. 54. – PP. 15-23.
92. *Ayodeji Abiodun, kuo Liu Yong.* Support vector ensemble for incipient fault diagnosis in nuclear plant components // Nuclear Engineering and Technology. – 2018. – Vol. 50. – No. 8. – PP. 1306-1313.
93. *Vapnik V., Chapelle O.* Bounds on Error Expectation for Support Vector Machines // Neural Computation. – 2000. – Vol. 12. – No. 9. – PP. 2013-2036.
94. *Banerjee Amit, Burlina Philippe, Meth Reuven.* Fast Hyperspectral Anomaly Detection via SVDD / Proc. of the 2007 IEEE International Conference on Image Processing. – IEEE, 2007.
95. *DongDong Li, Zhe Wang, Chenjie Cao et al.* Information entropy based sample reduction for support vector data description // Applied Soft Computing. – 2018. – Vol. 71. – PP. 1153-1160.
96. *Lin Chih-Jen.* Formulations of support vector machines: a note from an optimization point of view // Neural Computation. – 2001. – Vol. 13. – No. 2. – PP. 307-317.
97. *Platt J.C.* Fast training of support vector machines using sequential minimal optimization / Advances in Kernel Methods / Ed. by Bernhard Scholkopf, Christopher J.C. Burges,

- Alexander J. Smola. – Cambridge, MA, USA: MIT Press, 1999. – PP. 185-208. Электронный ресурс: <http://dl.acm.org/citation.cfm?id=299094.299105> (дата доступа: 20.07.2019).
98. *Du Jia-Zhi, Lu Wei-Gang, Wu Xiao-He et al.* L-SVM: A radius-margin-based SVM algorithm with LogDet regularization // *Expert Systems with Applications*. – 2018. – Vol. 102. – PP. 113-125.
99. *Takoua Kefi, Riadh Ksantini, Mohamed Becha Kaaniche et al.* A novel incremental covariance-guided one-class support vector machine // *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. – Springer. – 2016. – PP. 17-32.
100. *Тулупьев А.Л., Николенко С.И., Сироткин А.В.* Байесовские сети: логико-вероятностный подход. – М.: Наука, 2006. – 608 с.
101. *Finn B. Jensen Thomas Graven-Nielsen.* Bayesian networks and decision graphs. *Information Science and Statistics*. – 2nd edition. – Springer, 2007. Электронный ресурс: <http://gen.lib.rus.ec/book/index.php?md5=221D554B6699BF082377771696B32A6E> (дата доступа: 20.07.2019).
102. *Santoso N.I., Darken C., Povh G. et al.* Nuclear plant fault diagnosis using probabilistic reasoning / 199 IEEE Power Engineering Society Summer Meeting. *Conference Proceedings (Cat. No.99CH36364)*. – IEEE, 2017.
103. *Cai Baoping, Huang Lei, Xie Min.* Bayesian Networks in Fault Diagnosis // *IEEE Transactions on Industrial Informatics*. – 2017. – Vol. 13. – No. 5. – PP. 2227-2240.
104. *Lampis M., Andrews J. D.* Bayesian belief networks for system fault diagnostics // *Quality and Reliability Engineering International*. – 2009. – Vol. 25. – No. 4. – PP. 409-426.
105. *Lerner Uri, Parr Ronald, Koller Daphne et al.* Bayesian fault detection and diagnosis in dynamic systems // *AAAI/IAAI*. – 2000. – PP. 531-537.
106. *Murphy Kevin Patrick, Russell Stuart.* Dynamic bayesian networks: representation, inference and learning: Ph.D. thesis / University of California, Berkeley. – University of California, Berkeley Dissertation, 2002. – 268 p.
107. *Smyth Padhraic.* Hidden Markov models for fault detection in dynamic systems // *Pattern Recognition*. – 1994. – Vol. 27. – No. 1. – PP. 149-164.
108. *Soualhi A., Clerc G., Razik H. et al.* Fault detection and diagnosis of induction motors based on hidden Markov model / *Proc. of the 2012 XX-th International Conference on Electrical Machines*. – IEEE, 2012.
109. *Li Jinbo, Pedrycz Witold, Jamal Iqbal.* Multivariate time series anomaly detection: A framework of Hidden Markov Models // *Applied Soft Computing*. – 2017. – Vol. 60. – PP. 229-240.
110. *Bunks Carey, Mccarthy Dan, Al-Ani Tarik.* Condition-based Maintenance Of Machines Using Hidden Markov Models // *Mechanical Systems and Signal Processing*. – 2000. – Vol. 14. – No. 4. – PP. 597-612.
111. *Don Mihiran Galagedarage, Khan Faisal.* Dynamic process fault detection and diagnosis based on a combined approach of hidden Markov and Bayesian network model // *Chemical Engineering Science*. – 2019. – Vol. 201. – PP. 82-96.
112. *Ross Timothy J.* *Fuzzy Logic with Engineering Applications*. – John Wiley & Sons, Ltd, 2010. – 585 p.
113. *Shahinpoor M., Wells D.J.* Applications possibilities for fuzzy failure analysis, and diagnosis of reactor plant components and areas // *Nuclear Engineering and Design*. – 1980. – Vol. 61. – No. 1. – PP. 93-100.
114. *Koppen-Seliger B., Kiupel N., Schulte Kellinghaus H. et al.* A fault diagnosis concept for a high-pressure-preheater line / *Proc. of the 34-th IEEE Conference on Decision and Control*. – IEEE, 1995.
115. *Буянкин В.М, Захаров В.Г.* Прогнозирование неисправностей электропривода с использованием нечеткой нейронной сети // *Вестник Московского автомобильно-дорожного института (государственного технического университета)*. – 2007. – № 4. – С. 21-23.
116. *Wenli Yang, Kwang Y. Lee, S. Tobias Junker et al.* Fuzzy Fault Diagnosis and Accommodation System for Hybrid Fuel-Cell/Gas-Turbine Power Plant // *IEEE Transactions on Energy Conversion*. – 2010. – Vol. 25. – No. 4. – PP. 1187-1194.
117. *Seong Soo Choi, Ki Sig Kang, Han Gon Kim et al.* Development of an on-line fuzzy expert system for integrated alarm processing in nuclear power plants // *IEEE Transactions on*

Nuclear Science. – 1995. – Vol. 42. – No. 4. – PP. 1406-1418.

118. *Soon Heung Chang, Ki Sig Kang, Seong Soo Choi et al.* Development of the On-Line Operator Aid System OASYS Using A Rule-Based Expert System and Fuzzy Logic for Nuclear Power Plants // Nuclear Technology. – 1995. – Vol. 112. – No. 2. – PP. 266-294.

119. *Na Man Gyun, Lee Yoon Joon, Hwang In Joon.* A smart software sensor for feedwater flow measurement monitoring // IEEE Transactions on Nuclear Science. – 2005. – Vol. 52. – No. 6. – PP. 3026-3034.

120. *Holbert Keith E., Lin Kang.* Nuclear Power Plant Instrumentation Fault Detection Using Fuzzy Logic // Science and Technology of Nuclear Installations. – 2012. – Vol. 2012. – PP. 1-11.

121. *Gvishiani A.D., Agayan S.M., Bogoutdinov Sh. R. et al.* Algorithm FLARS and recognition of time series anomalies // System Research and Information Technologies. – 2004. – Vol. 3. – No. 7.

122. *Jang J.-S.R.* ANFIS: adaptive-network-based fuzzy inference system // IEEE Transactions on Systems, Man, and Cybernetics. – 1993. – Vol. 23. – No. 3. – PP. 665-685.

123. *Takagi Tomohiro, Sugeno Michio.* Fuzzy Identification of Systems and Its Applications to Modeling and Control // Readings in Fuzzy Sets for Intelligent Systems. – Elsevier, 1993. – PP. 387-403.

124. *Pillay Anand, Wang Jin.* Modified failure mode and effects analysis using approximate reasoning // Reliability Engineering & System Safety. – 2003. – Vol. 79. – No. 1. – PP. 69-85.

125. *Lo C.H., Chan P.T., Wong Y.K. et al.* Fuzzy-genetic algorithm for automatic fault detection in HVAC systems // Applied Soft Computing. – 2007. – Vol. 7. – No. 2. – PP. 554-560.

126. *Kecman Vojislav.* Learning and soft computing: support vector machines, neural networks, and fuzzy logic models. – MIT press, 2001. – 608 p.

127. *Zio E., Baraldi P., Popescu I. C.* A fuzzy decision tree method for fault classification in the steam generator of a pressurized water reactor // Annals of Nuclear Energy. – 2009. – Vol. 36. – No. 8. – PP. 1159-1169.

128. *Sakthivel N.R., Sugumaran V., Babudevasenapati S.* Vibration based fault diagnosis of monoblock centrifugal pump using decision tree // Expert Systems with Applications. – 2010. – Vol. 37. – No. 6. – PP. 4040-4049.

129. *Aydin Ilhan, Karakose Mehmet, Akin Erhan.* Artificial immune inspired fault detection algorithm based on fuzzy clustering and genetic algorithm methods / Proc. of the 2008 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications. – IEEE, 2008.

Поступила в редакцию 22.07.2019 г.

Авторы

Кацер Юрий Дмитриевич, аспирант,
E-mail: Iurii.Katser@skoltech.ru

Козицин Вячеслав Олегович, аспирант
E-mail: Vyacheslav.Kozitsin@skoltech.ru

Максимов Иван Владимирович, начальник отд. программно-методического обеспечения
E-mail: Maksimov@diaprom.ru

UDC 621.039.588

NPP EQUIPMENT FAULT DETECTION METHODS

Katser I.D., Kozitsin V.O., Maksimov I.V.*

Skolkovo Institute of Science and Technology

30, bld. 1 Bolshoy Boulevard, Moscow, Territory of Innovation Center

Skolkovo, 121205 Russia

*«KVANT PROGRAMM» LTD

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

ABSTRACT

Increased requirements for reliability and economic efficiency of nuclear power plants (NPP) lead to increased demand for modern solutions to the basic problems of diagnosing equipment faults, i.e., detecting, localizing, determining the causes and predicting the development of malfunctions. Advanced solutions based on statistical analysis, machine learning, intelligent signal processing and other methods have been successfully implemented in many industries, where they have proven their effectiveness, reducing the cost of equipment repair and maintenance.

The authors analyze methods used to solve problems of detecting faults and deviations in the operation of NPP equipment. The most common equipment fault detection methods are classified and compared, their advantages and disadvantages are described and the requirements for input data are given.

The result of the work is a generalization of fault detection methods to simplify their choice for solving specific problems. In addition, a review of literature sources is provided, links to works with a theoretical description of methods and examples of industrial applications are given.

Key words: fault detection, nuclear power plants, advanced analytics, diagnostics, data analysis.

REFERENCES

1. Arkadov G.V., Pavelko V.I., Finkel' B.M. *Diagnostic systems of VVER*. Moscow. Energoatomizdat Publ., 2010. 391 p. (in Russian).
2. Arkadov G.V., Egorov S.V., Katser I.D., Kovalev E.V., Kozitsin V.O., Maksimov I.V., Pavelko V.I., Slepov M.T. *Predictive analytics and diagnostics of NPP*. Moscow. Diaprom Publ., 2019. 72 p. (in Russian).
3. *Advanced Surveillance, Diagnostic and Prognostic Techniques in Monitoring Structures, Systems and Components in Nuclear Power Plants. Nuclear Energy Series no. NP-T-3.14*. Vienna: INTERNATIONAL ATOMIC ENERGY AGENCY, 2013. Available at: <https://www.iaea.org/publications/8763/advanced-surveillance-diagnostic-and-prognostic-techniques-in-monitoring-structures-systems-and-components-in-nuclear-power-plants> (accessed Jul 20, 2019).
4. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning*. Springer New York, 2009. 745 p.
5. Chiang L.H., Russell E.L., Braatz R.D. *Fault Detection and Diagnosis in Industrial Systems*. Springer London, 2001. 279 p.
6. Venkatasubramanian V., Rengaswamy R., Kavuri S. N. A review of process fault detection and diagnosis, *Computers & Chemical Engineering*, 27 (3), 2003, pp. 313-326.
7. Venkatasubramanian V., Rengaswamy R., Kavuri S. N., Yin K. A review of process fault detection and diagnosis: Part iii: Process history based methods. *Computers & chemical engineering*, 2003, 27 (3), pp. 327-346.
8. Qin S. J. Data-driven fault detection and diagnosis for complex industrial processes, *IFAC Proceedings Volumes*, 2009, 42 (8), pp. 1115-1125.

9. Ma J., Jiang J. Applications of fault detection and diagnosis methods in nuclear power plants: A review. *Progress in Nuclear Energy*, 2011, 53 (3), pp. 255-266.
10. Si X.-S., Wang W., Hu C.-H., Zhou D.-H. Remaining useful life estimation – a review on the statistical data driven approaches. *European Journal of Operational Research*, 2011, 213 (1), pp. 1-14.
11. An D., Choi J. H., Kim N. H. Options for prognostics methods: A review of data-driven and physics-based prognostics, *54-th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference*, American Institute of Aeronautics and Astronautics, 2013.
12. Dai X., Gao Z. From model, signal to knowledge: A data-driven perspective of fault detection and diagnosis. *IEEE Transactions on Industrial Informatics*, 2013, 9 (4), pp. 2226- 2238.
13. Aminikhanghahi S., Cook D. J. A survey of methods for time series change point detection. *Knowledge and Information Systems*, 2016, 51 (2), pp. 339-367.
14. Patel H. R., Shah V. A. Fault detection and diagnosis methods in power generation plants the indian power generation sector perspective: An introductory review. *PDPU Journal of Energy and Management*, 2018, 2 (2), pp. 31-49.
15. GOST R ISO 13381-1 2016. *Monitoring the status and diagnostics of machines. Prediction of technical condition. Part 1. General management*. Moscow. Standartinform Publ., 2017. 24 p. (in Russian).
16. Chandola Varun, Banerjee Arindam, Kumar Vipin. Anomaly detection. *ACM Computing Surveys*, 2009, 41 (3), pp. 1-58.
17. Ayo-Imoru R., Cilliers A. A survey of the state of condition-based maintenance (CBM) in the nuclear power industry. *Annals of Nuclear Energy*, 2018, 112, pp. 177-188.
18. Ivanovskij R.I. *Theory of Probability and Mathematical Statistics. Basics, applied aspects with examples and tasks in the Mathcad environment*. BHV-Peterburg Publ., 2008. 528 p. (in Russian).
19. Wald A. *Sequential analysis*. Courier Corporation, 1973. 213 p.
20. Hines J.W., Garvey D. Development and application of fault detectability performance metrics for instrument calibration verification and anomaly detection. *Journal of Pattern Recognition Research*, 2006, 1 (1), pp. 2-15.
21. Jin X., Guo Y., Sarkar S., Ray A., Edwards R.M. Anomaly detection in nuclear power plants via symbolic dynamic filtering. *IEEE Transactions on Nuclear Science*, 2011, 58 (1), pp. 277-288.
22. Maio F. D., Baraldi P., Zio E., Seraoui R. Fault detection in nuclear power plants components by a combination of statistical methods. *IEEE Transactions on Reliability*, 2013, 62 (4), pp. 833-845.
23. Tartakovsky A., Nikiforov I., Basseville M. *Sequential Analysis: Hypothesis Testing and Changepoint Detection*. Chapman and Hall/CRC, 2014. 575 p.
24. Montgomery D.C. *Introduction to Statistical Quality Control*. John Wiley & Sons, 2007. 752 p.
25. GOST R ISO 7870-1-2011. *Statistical methods. Control charts. Part 1. General principles, no. ISO 7870-1-2011*. Moscow. Standartinform Publ., 2011. 16 p. (in Russian).
26. Qin S.J. Statistical process monitoring: basics and beyond. *Journal of Chemometrics*, 2003, 17 (8-9), pp. 480-502.
27. Mujica L., Rodellar J., Fernandez A., Guemes A. Q-statistic and T2-statistic PCA based measures for damage assessment in structures. *Structural Health Monitoring: An International Journal*, 2010, 10 (5), pp. 539-553.
28. Zhao C., Gao F., Online fault prognosis with relative deviation analysis and vector autoregressive modeling. *Chemical Engineering Science*, 2015, 138, pp. 531-543.
29. Li W., Peng M., Wang Q. False alarm reducing in PCA method for sensor fault detection in a nuclear power plant. *Annals of Nuclear Energy*, 2018, 118, pp. 131-139.
30. Ge Z., Zhang M., Song Z. Nonlinear process monitoring based on linear subspace and

- bayesian inference. *Journal of Process Control*, 2010, 20 (5), pp. 676-688.
31. Xu C., Zhao S., Liu F. Distributed plant-wide process monitoring based on PCA with minimal redundancy maximal relevance. *Chemometrics and Intelligent Laboratory Systems*, 2017, 169, pp. 53-63.
32. Yang H.-H., Huang M.-L., Yang S.-W. Integrating auto-associative neural networks with hotelling T^2 control charts for wind turbine fault detection. *Energies*, 2015, 8 (10), pp. 12100-12115.
33. Xiao H., Huang D., Pan Y., Liu Y., Song K. Fault diagnosis and prognosis of wastewater processes with incomplete data by the auto-associative neural networks and ARMA model. *Chemometrics and Intelligent Laboratory Systems*, 2017, 161, pp. 96-107.
34. *Encyclopedia of Mass Spectrometry*, Elsevier, 2015. Available at: https://www.ebook.de/de/product/24358562/encyclopedia_of_mass_spectrometry.html (accessed Jul 20, 2019).
35. Ferrer-Riquelme A. Statistical control of measures and processes. *Comprehensive Chemometrics*, Elsevier, 2009, pp. 97-126.
36. Lucas J.M., Crosier R.B. Fast initial response for CUSUM quality-control schemes: Give your CUSUM a head start. *Technometrics*, 1982, 24 (3), pp. 199-205.
37. Paul W., Barnett N. Control charting instrumental analyses. *Laboratory Automation & Information Management*, 1995, 31 (2), pp. 141-148.
38. Simpson J.R., Keats J. Sensitivity study of the CUSUM control chart with an economic model. *International Journal of Production Economics*, 1995, 40 (1), pp. 1-19.
39. Wu C., Yu M., Zhuang F., Properties and enhancements of robust likelihood CUSUM control chart. *Computers & Industrial Engineering*, 2017, 114, pp. 80-100.
40. Fortea-Sanchis C., Escrig-Sos J. Quality control techniques in surgery: Application of cumulative sum (CUSUM) charts. *Cirugia Espanola (English Edition)*, 2019, 97 (2), pp. 65-70.
41. Bodnar O., Schmid W. CUSUM charts for monitoring the mean of a multivariate gaussian process. *Journal of Statistical Planning and Inference*, 2011, 141 (6), pp. 2055-2070.
42. Ferrer-Riquelme A. Statistical Control of Measures and Processes. *Comprehensive Chemometrics*, Elsevier, 2009, pp. 97-126.
43. Tobias P. Statistical process control and failure mode analysis. *Encyclopedia of Materials: Science and Technology*, Elsevier, 2001, pp. 8816-8824.
44. Senturk S., Erginel N., Kaya I., Kahraman C. Fuzzy exponentially weighted moving average control chart for univariate data with a real case application. *Applied Soft Computing*, 2014, 22, pp. 1-10.
45. Haq A., Khoo M.B. An adaptive multivariate EWMA chart. *Computers & Industrial Engineering*, 127, 2019, pp. 549-557.
46. Haq A., Khoo M. B. New adaptive EWMA control charts for monitoring univariate and multivariate coefficient of variation. *Computers & Industrial Engineering*, 2019, 131, pp. 28-40.
47. Park J., Jun C.-H. A new multivariate EWMA control chart via multiple testing. *Journal of Process Control*, 2015, 26, pp. 51-55.
48. Brodsky E., Darkhovsky B.S. *Nonparametric Methods in Change Point Problems*. Springer Science & Business Media, 2013. 210 p.
49. Chen J., Gupta A.K. *Parametric Statistical Change Point Analysis: with Applications to Genetics, Medicine, and Finance*. Springer Science & Business Media, 2011. 273 p.
50. Kawahara Y., Sugiyama M. Sequential change-point detection based on direct density ratio estimation, *Statistical Analysis and Data Mining*, 5 (2), 2011, pp. 114-127.
51. Garreau D. *Change-point detection and kernel methods*. Ph.D. thesis, PSL Research University (2017). 144 p.
52. Truong C., Oudre L., Vayatis N. *Selective review of offline change point detection methods*, arXiv. Available at: <http://arxiv.org/abs/1801.00718v2> (accessed Jul 20, 2019).
53. Lai T.L. Sequential changepoint detection in quality control and dynamical systems. *Journal of the Royal Statistical Society: Series B (Methodological)*, 1995, 57 (4), pp. 613-644.
54. D'Angelo M.F., Palhares R.M., Takahashi R.H., Loschi R. H., Baccarini L.M., Caminhas W.M.

- Incipient fault detection in induction machine stator-winding using a fuzzy bayesian change point detection approach. *Applied Soft Computing*, 2011, 11 (1), pp. 179-192.
55. Niculita O., Skaf Z., Jennions I.K. The application of bayesian change point detection in UAV fuel systems. *Procedia CIRP*, 2014, 22, pp. 115-121.
56. Zavaljevski N., Gross K. C. Sensor fault detection in nuclear power plants using multivariate state estimation technique and support vector machines. *Third International Conference of the Yugoslav Nuclear Society YUNSC 2000*, 2000.
57. Hines J.W., Usynin A. Mset performance optimization through regularization. *Nuclear Engineering and Technology*, 2005, 37 (2), pp. 177-184.
58. Sanchez-Fernandez A., Baldan F., Sainz-Palmero G., Benitez J., Fuente M. Fault detection based on time series modeling and multivariate statistical process control. *Chemometrics and Intelligent Laboratory Systems*, 2018, 182, pp. 57-69.
59. Filonov P., Lavrentyev A., Vorontsov A. *Multivariate Industrial Time Series with Cyberattack Simulation: Fault Detection Using an LSTM-based Predictive Data Model*. NIPS Time Series Workshop 2016, Barcelona, Spain, arXiv. Available at: <http://arxiv.org/abs/1612.06676v2> (accessed Jul 20, 2019).
60. Bishop C. M. *Pattern Recognition and Machine Learning*. Springer-Verlag, New York Inc., 2006. Available at: https://www.ebook.de/de/product/5324937/christopher_m_bishop_pattern_recognition_and_machine_learning.html (accessed Jul 20, 2019).
61. Brockwell P.J., Davis R.A., Calder M.V. *Introduction to Time Series and Forecasting*. Volume 2, Springer, 2002. 434 p.
62. Chatfield C. The Holt-Winters forecasting procedure. *Applied Statistics*, 1978, 27 (3), p. 264.
63. Tratar L.F., Strmcnik E. The comparison of Holt-Winters method and multiple regression method: A case study. *Energy*, 2016, 109, pp. 266-276.
64. Gers F. Learning to forget: continual prediction with LSTM, *IX-th International Conference on Artificial Neural Networks: ICANN 99, IEE*, 1999.
65. Greff K., Srivastava R.K., Koutnik J., Steunebrink B.R., Schmidhuber J. LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28 (10), pp. 2222-2232.
66. GOST R ISO 13379-12015. *Monitoring the status and diagnostics of machines. Methods of data interpretation and diagnosis. General leadership. Part 1*. Moscow. Standartinform Publ., 2015. 34 p. (in Russian).
67. Lu B., Upadhyaya B. Monitoring and fault diagnosis of the steam generator system of a nuclear power plant using data-driven modeling and residual space analysis. *Annals of Nuclear Energy*, 2005, 32 (9), pp. 897-912.
68. Li G., Hu X., Shen X., Chen X., Li Z. A novel unsupervised feature selection method for bioinformatics data sets through feature clustering, *2008 IEEE International Conference on Granular Computing, IEEE*, 2008, pp. 41-47.
69. Hajjem A., Bellavance F., Larocque D., Mixed-effects random forest for clustered data. *Journal of Statistical Computation and Simulation*, 2012, 84 (6), pp. 1313-1328.
70. Ardakani M.H., Shokry A., Escudero G., Graells M., Espuna A. Unsupervised automatic updating of classification models of fault diagnosis for novelty detection. *Computer Aided Chemical Engineering*, Elsevier, 2018, pp. 1123-1128.
71. Anderberg M. R. *Cluster Analysis for Applications: Probability and Mathematical Statistics*. Series of monographs and textbooks, Vol. 19. Academic press, 2014.
72. Bengio Y., Gingras F., Goulard B., Lina J.-M., Scott K. Gaussian mixture densities for classification of nuclear power plant data. *Computers and artificial intelligence*, 1998, 17 (2-3), pp. 189-209.
73. Baraldi P., Razavi-Far R., Zio E. Bagged ensemble of fuzzy c-means classifiers for nuclear transient identification. *Annals of Nuclear Energy*, 2011, 38 (5), pp. 1161-1171.
74. Skomorohov A.O. *Multidimensional Statistical Methods for Diagnosing Anomalous States*

of Nuclear Power Plants. Dr. Sci. (Eng.) Thesis. National Research Nuclear University MEPhI, 2011. 302 p. (in Russian).

75. Perasso A., Campi C., Toraci C., Benvenuto F., Piana M., Massone A.M. Application of possibilistic C-means for fault detection in nuclear power plant data. *Journal of Engineering for Gas Turbines and Power*, 2014, 137 (6), pp. 062901.

76. Kulkowski K., Grochowski M., Kobylarz A., Duzinkiewicz K. Application of data driven methods in diagnostic of selected process faults of nuclear power plant steam turbine. *Polish Control Conference*, Springer, 2017, pp. 631-640.

77. Wang B., Hu X., Li H. Rolling bearing performance degradation condition recognition based on mathematical morphological fractal dimension and fuzzy C-means. *Measurement*, 2017, 109, pp. 1-8.

78. Liu F.T., Ting K.M., Zhou Z.-H. Isolation Forest. *2008 Eighth IEEE International Conference on Data Mining, IEEE*, 2008.

79. Sun L., Versteeg S., Boztas S., Rao A. *Detecting Anomalous User Behavior using an Extended Isolation Forest Algorithm: An Enterprise Case Study*, arXiv. Available at: <http://arxiv.org/abs/1609.06676v1> (accessed Jul 20, 2019).

80. Tan S.C., Ting K.M., Liu T.F. Fast anomaly detection for streaming data. *Twenty-Second International Joint Conference on Artificial Intelligence*, 2011.

81. Ding Z., Fei M. An anomaly detection approach based on isolation forest algorithm for streaming data using sliding window. *IFAC Proceedings Volumes*, 2013, 46 (20), pp. 12-17.

82. Susto G.A., Beghi A., McLoone S. Anomaly detection through on-line isolation forest: An application to plasma etching. *2017 XXVIII-th Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC), IEEE*, 2017.

83. Mao W., Cao X., Zhou Q., Yan T., Zhang Y. Anomaly detection for power consumption data based on isolated forest, *2018 International Conference on Power System Technology (POWERCON), IEEE*, 2018.

84. Guha S., Mishra N., Roy G., Schrijvers O. Robust random cut forest based anomaly detection on streams. *International Conference on Machine Learning*, 2016, pp. 2712-2721.

85. Chen W.-R., Yun Y.-H., Wen M., Lu H.-M., Zhang Z.-M., Liang Y.-Z. Representative subset selection and outlier detection via isolation forest. *Analytical Methods*, 2016, 8 (39), pp. 7225-7231.

86. Tax D.M., Duin R.P. Support vector data description. *Machine Learning*, 2004, 54 (1), pp. 45-66.

87. Park J., Kang D., Kim J., Kwok J.T., Tsang I.W. SVDD-based pattern denoising. *Neural Computation*, 2007, 19 (7), pp. 1919-1938.

88. Chalapathy R., Menon A.K., Chawla S. *Anomaly detection using one-class neural networks*, arXiv. Available at: <http://arxiv.org/abs/1802.06360> (accessed Jul 20, 2019).

89. Zhang Y., Liu X.-D., Xie F.-D., Li K.-Q. Fault classifier of rotating machinery based on weighted support vector data description. *Expert Systems with Applications*, 2009, 36 (4), pp. 7928-7932.

90. Wang X., lai Chung F., Wang S. Theoretical analysis for solution of support vector data description, *Neural Networks*, 24 (4), 2011, pp. 360-369.

91. Tax D., Ypma A., Duin R. Support vector data description applied to machine vibration analysis, *Proc. of the V-th Annual Conference of the Advanced School for Computing and Imaging*. Citeseer, 1999, v. 54, pp. 15-23.

92. Ayodeji A., kuo Liu Y. Support vector ensemble for incipient fault diagnosis in nuclear plant components. *Nuclear Engineering and Technology*, 2018, 50 (8), pp. 1306-1313.

93. Vapnik V., Chapelle O. Bounds on error expectation for support vector machines. *Neural Computation*, 2000, 12 (9), pp. 2013-2036.

94. Banerjee A., Burlina P., Meth R. Fast hyperspectral anomaly detection via SVDD. *2007 IEEE International Conference on Image Processing, IEEE*, 2007.

95. Li D., Wang Z., Cao C., Liu Y. Information entropy based sample reduction for support vector data description. *Applied Soft Computing*, 2018, 71, pp. 1153-1160.

96. Lin C.-J. Formulations of support vector machines: a note from an optimization point of view. *Neural Computation*, 2001, 13 (2), pp. 307-317.
97. Platt J.C. *Fast Training of Support Vector Machines using Sequential Minimal Optimization*. – *Advances in Kernel Methods*. Ed. by B. Scholkopf, C.J.C. Burges, A.J. Smola. MIT Press, Cambridge, MA, USA, 1999, Chapter «Fast Training of Support Vector Machines Using Sequential Minimal Optimization», pp. 185-208. Available at: <http://dl.acm.org/citation.cfm?id=299094.299105> (accessed Jul 20, 2019).
98. Du J.-Z., Lu W.-G., Wu X.-H., Dong J.-Y., Zuo W.-M. L-SVM: A radius-marginbased SVM algorithm with LogDet regularization. *Expert Systems with Applications*, 2018, 102, pp. 113-125.
99. Kefi T., Ksantini R., Kaaniche M. B., Bouhoula A. A novel incremental covariance-guided one-class support vector machine, *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, Springer, 2016, pp. 17-32.
100. Tulup'ev A.L., Nikolenko S.I., Sirotkin A.V. *Bayesian networks: a logical-probabilistic approach*. Moscow. Nauka Publ., 2006. 608 p. (in Russian).
101. Finn B., Jensen T.G.-N. *Bayesian Networks and Decision Graphs – 2-nd Edition*. Information Science and Statistics, Springer, 2007. Available at: <http://gen.lib.rus.ec/book/index.php?md5=221D554B6699BF08237771696B32A6E> (accessed Jul 20, 2019).
102. Santoso N., Darken C., Povh G., Erdmann J. Nuclear plant fault diagnosis using probabilistic reasoning, *199 IEEE Power Engineering Society Summer Meeting. Conference Proceedings (Cat. No.99CH36364)*, IEEE, 2017.
103. Cai B., Huang L., Xie M. Bayesian networks in fault diagnosis. *IEEE Transactions on Industrial Informatics*, 2017, 13 (5), pp. 2227-2240.
104. Lampis M., Andrews J.D. Bayesian belief networks for system fault diagnostics. *Quality and Reliability Engineering International*, 2009, 25 (4), pp. 409-426.
105. Lerner U., Parr R., Koller D., Biswas G. Bayesian fault detection and diagnosis in dynamic systems. *AAAI/IAAI*, 2000, pp. 531-537.
106. Murphy K.P., Russell S. *Dynamic Bayesian Networks: Representation, Inference and Learning*. Ph.D. thesis, University of California, Berkeley, 2002. 268 p.
107. Smyth P. Hidden Markov models for fault detection in dynamic systems. *Pattern Recognition*, 1994, 27 (1), pp. 149-164.
108. Soualhi A., Clerc G., Razik H., Lebaroud A. Fault detection and diagnosis of induction motors based on hidden Markov model. *2012 XX-th International Conference on Electrical Machines, IEEE*, 2012.
109. Li J., Pedrycz W., Jamal I. Multivariate time series anomaly detection: A framework of hidden Markov models. *Applied Soft Computing*, 2017, 60, pp. 229-240.
110. Bunks C., McCarthy D., Al-Ani T. Condition-based Maintenance Of Machines Using Hidden Markov Models. *Mechanical Systems and Signal Processing*, 14 (4), 2000, pp. 597-612.
111. Don M.G., Khan F. Dynamic process fault detection and diagnosis based on a combined approach of hidden Markov and bayesian network model. *Chemical Engineering Science*, 2019, 201, pp. 82-96.
112. Ross T.J. *Fuzzy Logic with Engineering Applications*. John Wiley & Sons, Ltd, 2010. 585 p.
113. Shahinpoor M., Wells D. Applications possibilities for fuzzy failure analysis, and diagnosis of reactor plant components and areas. *Nuclear Engineering and Design*, 1980, 61 (1), pp. 93- 100.
114. Koppen-Seliger B., Kiupel N., Kellinghaus H.S., Frank P. A fault diagnosis concept for a high-pressure-preheater line. *Proceedings of 1995 XXXIV-th IEEE Conference on Decision and Control, IEEE*, 1995.
115. Bujankin V., Zaharov V. Predicting drive faults using a fuzzy neural network. *Vestnik Moskovskogo Avtomobil'no-Dorozhnogo Instituta (Gosudarstvennogo Tehnicheskogo Universiteta)*, 2007, 4, pp. 21-23 (in Russian).
116. Yang W., Lee K.Y., Junker S.T., Ghezal-Ayagh H. Fuzzy fault diagnosis and accommodation system for hybrid fuel-cell/gas-turbine power plant. *IEEE Transactions on*

Energy Conversion, 2010, 25 (4), pp. 1187-1194.

117. Choi S.S., Kang K.S., Kim H.G., Chang S.H. Development of an on-line fuzzy expert system for integrated alarm processing in nuclear power plants. *IEEE Transactions on Nuclear Science*, 1995, 42 (4), pp. 1406-1418.

118. Chang S.H., Kang K.S., Choi S.S., Kim H.G., Jeong H.K., Yi C.U. Development of the on-line operator aid system OASYS using a rule-based expert system and fuzzy logic for nuclear power plants. *Nuclear Technology*, 1995, 112 (2), pp. 266-294.

119. Na M.G., Lee Y.J., Hwang I.J. A smart software sensor for feedwater flow measurement monitoring. *IEEE Transactions on Nuclear Science*, 2005, 52 (6), pp. 3026-3034.

120. Holbert K.E., Lin K. Nuclear power plant instrumentation fault detection using fuzzy logic. *Science and Technology of Nuclear Installations*, 2012, v. 2012, pp. 1-11.

121. Gvishiani A., Agayan S., Bogoutdinov S.R., Tikhotski S., Hinderer J., Bonnin J., Diamant M. Algorithm flars and recognition of time series anomalies. *System Research and Information Technologies*, 2004, 3 (7).

122. Jang J.-S. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 1993, 23 (3), pp. 665-685.

123. Takagi T., Sugeno M. Fuzzy identification of systems and its applications to modeling and control. *Readings in Fuzzy Sets for Intelligent Systems*, Elsevier, 1993, pp. 387-403.

124. Pillay A., Wang J. Modified failure mode and effects analysis using approximate reasoning. *Reliability Engineering & System Safety*, 79 (1), 2003, pp. 69-85.

125. Lo C., Chan P., Wong Y., Rad A., Cheung K. Fuzzy-genetic algorithm for automatic fault detection in HVAC systems. *Applied Soft Computing*, 2007, 7 (2), pp. 554-560.

126. Kecman V. *Learning and Soft Computing: Support Vector Machines, Neural Networks, and Fuzzy Logic Models*. MIT press, 2001. 608 p.

127. Zio E., Baraldi P., Popescu I.C. A fuzzy decision tree method for fault classification in the steam generator of a pressurized water reactor. *Annals of Nuclear Energy*, 2009, 36 (8), pp. 1159-1169.

128. Sakthivel N., Sugumaran V., Babudevasenapati S. Vibration based fault diagnosis of monoblock centrifugal pump using decision tree. *Expert Systems with Applications*, 2010, 37 (6), pp. 4040-4049.

129. Aydin I., Karakose M., Akin E. Artificial immune inspired fault detection algorithm based on fuzzy clustering and genetic algorithm methods. *2008 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, IEEE*, 2008.

Authors

Katser Iurii Dmitrievich, PhD Student

E-mail: Iurii.Katser@skoltech.ru

Kozitsin Vyacheslav Olegovich, PhD Student

E-mail: Vyacheslav.Kozitsin@skoltech.ru

Maksimov Ivan Vladimirovich, Head of Department

E-mail: Maksimov@diaprom.ru