

## Построение модели предиктивной аналитики неисправностей промышленного оборудования

А.В. Чернухин <sup>1</sup>✉, Е.А. Богданова <sup>2</sup>, Т.В. Савицкая <sup>1</sup>

<sup>1</sup> Российский химико-технологический университет имени Д.И. Менделеева,  
г. Москва, 125047, Россия

<sup>2</sup> Московский государственный университет имени М.В. Ломоносова,  
г. Москва, 119991, Россия

### Ссылка для цитирования

Чернухин А.В., Богданова Е.А., Савицкая Т.В. Построение модели предиктивной аналитики неисправностей промышленного оборудования // Программные продукты и системы. 2024. Т. 37. № 2. С. 254–261. doi: 10.15827/0236-235X.142.254-261

### Информация о статье

Группа специальностей ВАК: 2.3.1

Поступила в редакцию: 31.10.2023

После доработки: 11.11.2023

Принята к публикации: 26.12.2023

**Аннотация.** В статье описаны новые подходы к построению модели предиктивной аналитики неисправностей промышленного оборудования. Актуальность исследования обусловлена необходимостью заблаговременно идентифицировать неисправности, приводящие к снижению эффективности работы или простоям крупных производственных линий промышленного предприятия. В рамках исследования были изучены современные подходы, использующие машинное обучение для решения схожих задач, подробно описаны их достоинства и недостатки. Данные для обучения моделей включают сведения о показаниях датчиков, измеряющих токи, температуры, давления и вибрации, для шести эксгаустеров за три года. Для обучения и тестирования были отобраны только техмesta с наличием неисправностей за анализируемый период. В связи со сложной взаимосвязью между показаниями датчиков и состоянием эксгаустера было принято решение о создании предсказательной модели, основанной на мягком голосовании между тремя алгоритмами, имеющими различные подходы к классификации: сверточная нейронная сеть, логистическая регрессия и метод опорных векторов. Предложенный подход реализован с помощью высокоуровневого языка программирования Python с использованием дистрибутива Anaconda. Описан порядок выполнения исследования, представлены блок-схемы разработанных алгоритмов и их подробное описание. Проведено всестороннее тестирование разработанного программного обеспечения, реализующего модель прогнозирования неисправностей. Результаты исследования подтверждают работоспособность предлагаемой модели прогнозирования неисправности технических узлов оборудования, которая может быть адаптирована для предиктивной аналитики неисправностей большого числа типов промышленного оборудования крупных предприятий металлургической, химической и других отраслей промышленности.

**Ключевые слова:** математическое моделирование, интеллектуальный анализ данных, предиктивная аналитика, машинное обучение, нейронные сети, промышленное оборудование, прогнозирование неисправностей

**Введение.** Проблема возникновения неисправностей промышленного оборудования, приводящих к снижению эффективности работы или к простоям крупных производственных линий, а следовательно, к убыткам, актуальна во всем мире [1, 2]. Вместе с тем активно продолжается автоматизация всех отраслей промышленного производства, которая обуславливает развитие информационно-технических систем предприятия [3], а значит, систем сбора, хранения и мониторинга состояния оборудования в режиме реального времени. При этом эксперты в области промышленных информационных систем сходятся во мнении, что аккумулированные большие объемы данных могут использоваться для прогнозирования неисправностей задолго до их возникновения [4, 5]. Для этого необходимо построение отдельной подсистемы предиктивной аналитики, исполь-

зуемой для гибкого планирования технического обслуживания и ремонта [6].

Методы прогнозирования на основе классического машинного обучения широко используются в области диагностики и прогнозирования неисправностей оборудования благодаря хорошей интерпретируемости результатов обучения, относительно невысоким требованиям к вычислительным ресурсам и широкому выбору подходов, которые обеспечивают разносторонний анализ данных [7, 8]. Хотя классические алгоритмы машинного обучения хорошо показывают себя в диагностике и прогнозировании неисправностей, они уступают нейросетевым алгоритмам в идентификации сложных взаимосвязей между показаниями большого числа датчиков и состоянием оборудования [9, 10]. Было проведено большое количество исследований, направленных на разработку алгорит-

мов на основе нейронных сетей [11], но в подавляющем большинстве случаев диагностика в них осуществляется только для одного технического места (подшипник, ротор и др.), что говорит о сложности или невозможности масштабирования таких подходов [12, 13]. В подобных работах для обучения и тестирования используются наборы данных с большим количеством примеров неисправностей, за счет чего достигается высокая точность предсказания (ассигасу = 0.8–0.9). Однако возникновение неисправности – достаточно редкое явление в работе промышленного оборудования, в связи с чем часто отсутствует возможность накопления обширной библиотеки отказов [14]. Это является основной трудностью в диагностике неисправной работы в условиях реального производства с помощью нейронных сетей, так как они в таких случаях проявляют склонность к переобучению [15, 16].

Соответственно, в системе предиктивной аналитики, работающей в режиме реального времени, необходимо использовать как методы классического машинного обучения, так и нейросетевые алгоритмы, за счет чего будут нивелированы их недостатки, связанные с переобучением в условиях небольшого количества данных о неисправностях [17, 18]. Для повышения точности предсказания между моделями в ансамбле будет проводиться так называемое мягкое голосование. Модель необходимо обучать на данных с долей неисправной работы менее 15 % по каждому техническому месту, а раннее прогнозирование возникновения неисправностей для всех ключевых технических мест следует осуществлять одновременно.

Целью данного исследования является разработка комплексной модели, позволяющей прогнозировать неисправности промышленного оборудования с учетом специфики реальных промышленных данных. Ее отличительной особенностью является использование ансам-

блевого подхода к предсказанию неисправностей, основанного на проведении операции голосования между методами классического машинного обучения и нейросетевым алгоритмом, что позволяет максимально разносторонне рассмотреть признаковое пространство и выявить наиболее важные свойства.

Разработанное ПО позволит на основе текущих данных о состоянии оборудования, получаемых с датчиков, заблаговременно идентифицировать зарождающиеся неисправности.

Для обучения моделей использованы данные, полученные от ПАО «Северсталь», в качестве оборудования выступают эксгаустеры агломерационной машины – центробежные нагнетатели, осуществляющие просос воздуха через слой шихты.

### Предобработка данных

В наборе обучающих данных присутствуют сведения о показаниях датчиков для шести эксгаустеров за три года (с 01.01.2019 по 31.12.2021) в десятисекундных интервалах. Формат данных представлен в таблице 1.

Датчики измеряют такие показания состояния оборудования, как токи (амперы), температуры (градусы Цельсия), давления (КПа), вибрации (мм/с). Всего проводился анализ показаний 16 датчиков.

Информация о неисправностях технических мест эксгаустеров (Т.М.  $i$ ) была предоставлена в виде таблицы с бинарным кодированием (0 – штатное состояние технического места, 1 – неисправная работа) (табл. 2).

Количество и набор технических мест отличались для каждого из эксгаустеров (от 20 до 35). Для обучения и тестирования были отобраны техместа с наличием неисправностей за анализируемый период – маслоохладитель, подшипник опорный, вибропреобразователь, электроаппаратура, электродвигатель, улита, корпус, ротор.

Таблица 1

Формат данных о показаниях датчиков за анализируемый период

Table 1

Format of data on sensor readings over the analyzed period

Дата	Датчик 1	Датчик 2	...	Датчик 15	Датчик 16
01.01.2019 00:00:00	123	0	...	345	17
01.01.2019 00:00:10	135	0.57	...	320	17
01.01.2019 00:00:20	127	0.93	...	387	19
...	...	...	...	...	...
31.12.2021 23:59:40	69	2.4	...	341	0
31.12.2021 23:59:50	63	1.2	...	390	3

Таблица 2

**Формат данных, содержащих метки неисправностей за анализируемый период**

Table 2

**Format of data containing fault labels over the analyzed period**

Дата	Т.М. 1	Т.М. 2	...	Т.М. 20	Т.М. 21
01.01.2019 00:00:00	0	0	...	1	0
01.01.2019 00:00:10	0	0	...	1	0
01.01.2019 00:00:20	0	0	...	1	0
...	...	...	...	...	...
31.12.2021 23:59:40	1	0	...	0	0
31.12.2021 23:59:50	1	0	...	0	0

Предобработка показаний датчиков включала в себя следующие этапы.

- *Удаление выбросов.* Производились обнуление отрицательных показаний датчиков и уменьшение амплитуды значений, превышающих среднее более чем в сто раз (так как подобные значения не являются нормальными показаниями датчиков и негативно сказываются на обучении).

- *Приведение данных к часовым интервалам из десятисекундных.* Показания с шагом в 10 секунд являются избыточными и неоптимальными для обучения предсказательного алгоритма в связи с зашумленностью данных и большим объемом занимаемой памяти (необходимы хранение и работа с таблицей, содержащей 9 460 800 строк для каждого эксгаустера). Для дальнейшей работы для каждого из часовых интервалов (360 строк) рассчитывались статистические характеристики, такие как среднее, медиана, максимальные и минимальные значения. В дальнейшем именно эти значения использованы в качестве признаков при обучении модели.

- *Стандартизация и замена пропущенных значений.* В связи с различной природой показаний датчиков производилась их стандартизация. Для этого рассчитывались обобщенное для всех эксгаустеров среднее значение и стандартное отклонение для каждого датчика, которые и использовались для стандартизации. Оставшиеся пропущенные значения заполнялись путем интерполяции.

- *Добавление новых признаков.* Для получения информации об отклонении показаний датчиков за текущий час от показаний за предыдущие сутки рассчитывалась разность между средними значениями за эти периоды. Полученные изменения в дальнейшем также использовались в качестве признаков, поскольку позволяют не только учитывать информацию о локальных изменениях состояния

системы, но и выявлять отклонения от состояния за более долгий промежуток времени.

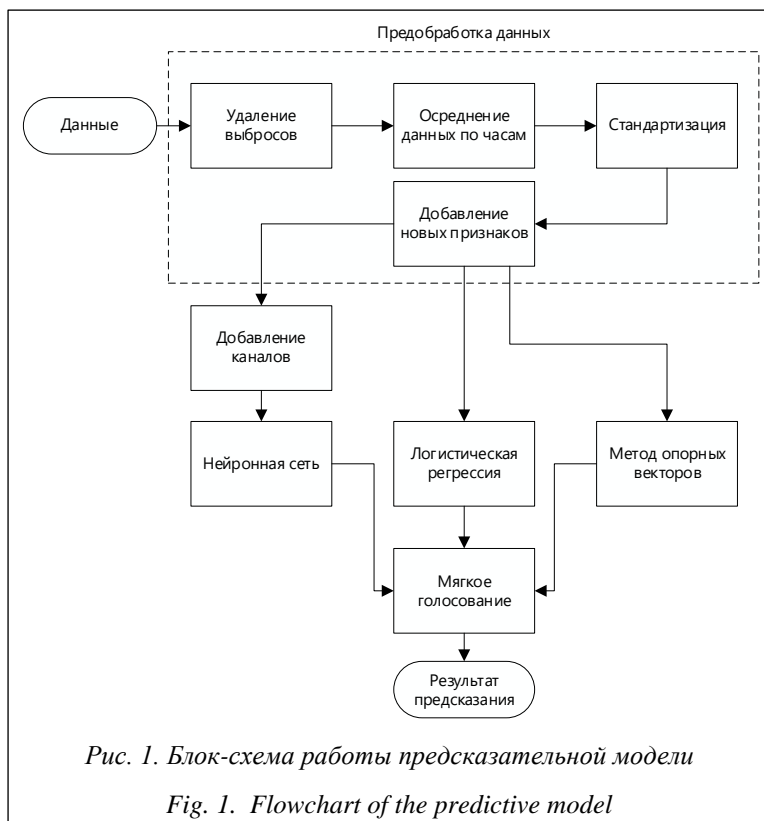
Весь набор данных состоит из 26 280 векторов, характеризующих часовые интервалы для шести эксгаустеров. Для тренировочного датасета отбирались интервалы для каждого эксгаустера, содержащие неисправности, при их отсутствии – фрагмент со штатным состоянием. Для валидации отбирались интервалы, следующие после отобранных для обучения и содержащие хотя бы одну продолжительную (более 3 суток) неисправность из всех эксгаустеров. В качестве тестового набора отбирались самые поздние интервалы, содержащие неисправности. В связи с тем, что периоды неисправного состояния оборудования для разных технических мест не совпадали, для каждого из них разделение происходило индивидуально, с учетом причин, повлекших за собой неисправность.

### Архитектура предсказательной модели

В связи со сложной взаимосвязью между показаниями датчиков и состоянием эксгаустера было принято решение о создании предсказательной модели, основанной на мягком голосовании между тремя алгоритмами, имеющими различные подходы к классификации (рис. 1). Суть данного ансамблевого метода заключается в подборе к каждому из предсказательных алгоритмов весов, отражающих значимость прогноза. Подбор весов осуществлялся с использованием метода градиентного бустинга. По итогу для каждого объекта рассчитывалась вероятность принадлежности к классу по следующей формуле:

$$P_1 = w_a p_{a1} + w_b p_{b1} + w_c p_{c1},$$

где  $P_1$  – итоговая вероятность принадлежности объекта к классу 1 (неисправность);  $p_{a1}$ ,  $p_{b1}$ ,  $p_{c1}$  – вероятности принадлежности объекта к классу 1, предсказанные тремя отдельными алгорит-



мами;  $w_a$ ,  $w_b$ ,  $w_c$  – веса, присваиваемые прогнозам отдельных алгоритмов.

Для голосования использованы сверточная нейронная сеть, логистическая регрессия и метод опорных векторов. Выбор обусловлен низкой корреляцией их предсказаний друг с другом, составляющей менее 0.6, с относительно высоким качеством предсказания для большей части анализируемых технических мест (значение индекса Жаккара выше 0.5).

Для логистической регрессии выбран базовый алгоритм оптимизации (LBFGS), максимальное количество итераций – 2 000 (что обусловлено большим количеством признаков). Метод опорных векторов обучался с использованием ядра rbf (Radial Basis Function) в связи с нелинейной разделимостью объектов в анализируемом наборе данных. Данные для моделей подавались на вход в виде векторов размера 96 (по 6 признаков для каждого из 16 датчиков), ответом являлась метка 0 или 1 в случае неисправности в течение часа, описываемого вектором признаков.

Было опробовано несколько архитектур с разным количеством сверточных и полносвязных слоев. Итоговая нейронная сеть (рис. 2) содержит базовые слои, в которых происходит подбор весов.

- **Сверточный слой (Conv1D).** Выполняет функции обобщения признаков в каналах и

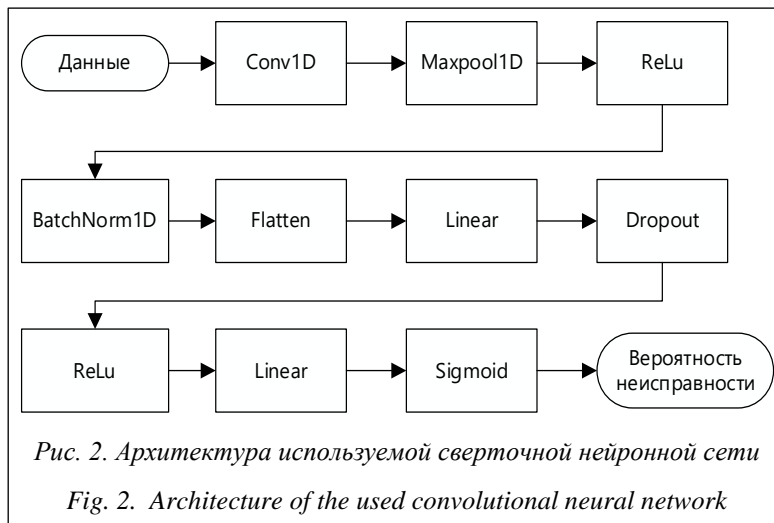
выявления значимых паттернов с увеличением числа каналов с 6 до 32. В качестве каналов используются статистические характеристики, рассчитанные для показателей каждого из 16 датчиков, в частности, среднее, медиана, максимальное и минимальное значения за час, а также разность между средним и медианой за час и за месяц. В связи с размером входного тензора выбран размер ядра свертки, равный 3. После сверточного слоя располагается слой подвыборки по максимальному значению (MaxPooling), который уменьшает в два раза размер тензора. В качестве функции активации использовалась выпрямленная линейная функция активации (ReLU).

- **Два полносвязных слоя (Linear)** с уменьшением количества каналов (100, 1). Для первого слоя использовалась функция активации ReLu. В последнем слое непосредственно происходит предсказание наличия неисправности и используется сигмоидная функция активации (Sigmoid), которая выводит вероятность принадлежности объекта к классу 1 (наличие неисправности).

Таким образом, на вход алгоритм принимает 4D-тензор размера  $6 \times 16$ , на выходе получается одно число, отражающее вероятность наличия неисправности за час, который описывается входным тензором.

В целях нормализации и регуляризации после сверточных слоев использовалась пакетная нормализация (Batch Normalization), а после первых двух полносвязных слоев применялся метод прореживания (Dropout) со значением отсева 0.3 (из-за наличия пакетной нормализации значение выбрано меньше стандартного 0.5).

В качестве оптимизатора был выбран оптимизатор Адама. Выбор обусловлен его эффективностью и возможностью добавления L2 регуляризации (параметр `weight_decay`), которая необходима для ограничения значения весов для признаков, что препятствует переобучению и способствует поиску общих закономерностей. В результате подбора гиперпараметров (настраиваемых вручную параметров обучения) использована скорость обучения, равная 0.0001, и `weight_decay` = 0.001. Для расчета



ошибки применялась функция потерь BCELoss, оптимальная для решения задачи бинарной классификации. При оптимизации также подбирался размер пакета (batch size), оказывающий влияние на эффективность Batch Normalization и на продуктивность обучения. Исходя из размера обучающей выборки выбран batch size = 16. Обучение проводилось в течение 30 эпох, сохранялась модель с наименьшим значением функции потерь на валидационном наборе данных.

Метрикой качества выступает индекс Жаккара, рассчитанный по формуле

$$J = \frac{TP}{TP + FP + FN},$$

где  $J$  – индекс Жаккара;  $TP$  – истинно положительные значения из матрицы путаницы;  $FP$  – ложно положительные;  $FN$  – ложно отрицательные. Выбор данной метрики обусловлен более объективной работой с наборами данных, содержащими низкую долю одного из классов.

Программное обеспечение разработано на высокоуровневом языке программирования Python с использованием дистрибутива Anaconda, включающего набор свободных библиотек, используемых при работе с данными и в машинном обучении.

### Описание и сравнение полученных результатов

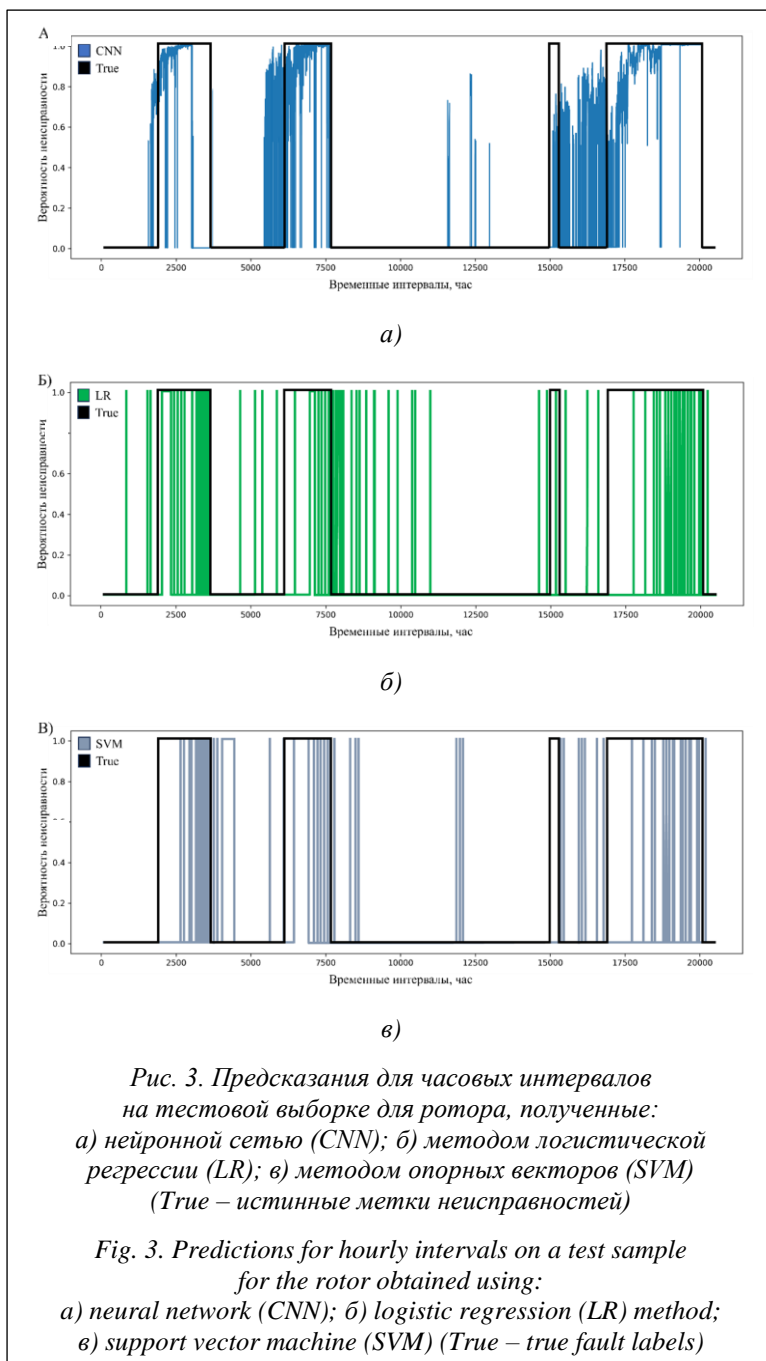
На первом этапе работы были обучены предсказательные модели отдельно для каждого технического места. В результате обучения нейронной сети получены вероятности неисправности в каждый момент времени. Для идентификации неисправностей в разных

техместах индивидуально подбирались пороги принятия решения. На рисунке 3а представлено распределение вероятностей наличия неисправности на тестовой выборке для ротора (в качестве порога взято значение 0.5), при этом индекс Жаккара равен 0.6 (<http://www.swsys.ru/uploaded/image/2024-2/5.jpg>). В тестовых временных интервалах для трех эксгаустеров, объединенных в общий тестовый набор, наблюдаются три продолжительные неисправности и одна более короткая (рис. 3а). Можно заметить,

что в трех случаях модель начинала присваивать высокую вероятность развития неисправности заранее, до официального начала, обозначенного оператором. Это, с одной стороны, отрицательно повлияло на значение метрики качества, а с другой, является положительным моментом, позволяя диагностировать начало развития неисправности до того, как это явным образом скажется на работе эксгаустера и будет замечено оператором. Однако одна из неисправностей не была диагностирована, что может быть связано с причиной, слабо представленной в обучающем наборе данных.

Можно заметить, что результаты, полученные другими моделями, достаточно сильно отличаются и относят к неисправностям периоды их активного развития (рис. 3б, 3в), а также не идентифицируют непродолжительную неисправность, что подтверждает упомянутое предположение. При этом значение метрики качества для логистической регрессии равно 0.51, для метода опорных векторов – 0.4 (<http://www.swsys.ru/uploaded/image/2024-2/5.jpg>). Полученные данные об особенностях прогнозирования разных этапов развития неисправности ротора свидетельствуют о возможности улучшения качества предсказания при использовании ансамблевого подхода, объединяющего ранее названные модели. Метрики качества для используемых подходов, включая ансамблевые, отображены на рисунке <http://www.swsys.ru/uploaded/image/2024-2/5.jpg>.

Благодаря использованию ансамблевого подхода, включающего операцию мягкого голосования между моделями, для ряда технических мест удалось значительно улучшить качество предсказания на тестовой выборке. Наилучшие показатели наблюдаются для кор-



пуса, улита, электроаппаратуры и вибропреобразователя. Наиболее высокое качество предсказания получили технические места, неис-

правная работа которых имеет быстрое развитие (электроаппаратура, вибропреобразователь, электродвигатель), а также с наиболее заметными и легко идентифицируемыми проявлениями неисправной работы (улита, корпус, вибропреобразователь). Следовательно, разметка данных для этих точек может производиться в более оперативном режиме, что важно для обучения моделей с учителем. Однако для остальных техузлов, несмотря на более низкие значения метрик, обученные модели предсказывают зарождение неисправности до момента идентификации ее сотрудниками, что позволит заранее подготовиться к развитию аномалии в работе оборудования и принять необходимые превентивные меры.

### Заключение

Таким образом, с использованием разработанных моделей можно проводить исследования работы эксгаустеров в режиме реального времени, а их результаты применять для планирования работ по оптимальному техническому обслуживанию.

В текущем виде разработанное ПО может использоваться в пилотном проекте на одном из промышленных предприятий и покажет свою эффективность при прогнозировании неисправностей техузлов эксгаустера. В дальнейшем, в случае получения данных по другим типам

### Список литературы

1. James A.T., Gandhi O., Deshmukh S. Fault diagnosis of automobile systems using fault tree based on digraph modeling. *Int. J. Syst. Assur. Eng. Manag.*, 2018, vol. 9, pp. 494–508. doi: 10.1007/s13198-017-0693-6.
2. Bhakta K., Sikder N., Nahid A.A., Islam M.M.M. Fault diagnosis of induction motor bearing using Cepstrum-based preprocessing and ensemble learning algorithm. *Proc. Int. Conf. ECCE*, 2019, pp. 1–6. doi: 10.1109/ECACE.2019.8679223.
3. Трофимов В.В. Алгоритмизация и программирование. М.: Юрайт, 2017. 137 с.
4. Оклей П.И. Прогнозирование остаточного ресурса и вероятности наступления отказа оборудования – основа проектирования производственной программы ремонтных работ тепловой электростанции // *Контроллинг*. 2017. № 65. С. 54–63.

5. Nan X., Zhang B., Liu C., Gui Z., Yin X. Multi-modal learning-based equipment fault prediction in the internet of things. *Sensors*, 2022, vol. 22, no. 18, art. 6722. doi: 10.3390/s22186722.
6. Lv H., Chen J., Pan T., Zhang T., Feng Y., Liu Sh. Attention mechanism in intelligent fault diagnosis of machinery: A review of technique and application. *Measurement*, 2022, vol. 199, art. 111594. doi: 10.1016/j.measurement.2022.111594.
7. Боровский А.С., Шумилина Н.А. Нечеткая ситуационная сеть для оценки проектного риска отказа оборудования // Тр. ИСА РАН. 2018. Т. 68. № 1. С. 87–93.
8. Xu Z., Mei X., Wang X., Yue M., Jin J., Yang Y., Li Ch. Fault diagnosis of wind turbine bearing using a multi-scale convolutional neural network with bidirectional long short term memory and weighted majority voting for multi-sensors. *Renewable Energy*, 2022, vol. 182, pp. 615–626. doi: 10.1016/J.RENENE.2021.10.024.
9. Антонов А.В. Методика статистического анализа данных об отказах оборудования АЭС в условиях неоднородного потока событий // Изв. вузов. Ядерная энергетика. 2016. № 3. С. 20–29. doi: 10.26583/npe.2016.3.03.
10. Cheng Y., Yuan H., Liu H., Lu C. Fault diagnosis for rolling bearing based on SIFT-KPCA and SVM. *Eng. Computations*, 2017, vol. 34, no. 1, pp. 53–65. doi: 10.1108/EC-01-2016-0005.
11. Mao W., Feng W., Liu Y., Zhang D., Liang X. A new deep auto-encoder method with fusing discriminant information for bearing fault diagnosis. *MSSP*, 2021, vol. 150, art. 107233. doi: 10.1016/j.ymsp.2020.107233.
12. Иванов В.К., Виноградова Н.В., Палюх Б.В., Сотников А.Н. Современные направления развития и области приложения теории Демпстера–Шафера // ИИИПР. 2018. № 4. С. 32–42. doi: 10.14357/20718594180403.
13. Javed K., Gouriveau R., Zerhouni N. State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels. *MSSP*, 2017, vol. 94, no. 9, pp. 214–236. doi: 10.1016/j.ymsp.2017.01.050.
14. Hossain M., Abu-Siada A., Muyeen S. Methods for advanced wind turbine condition monitoring and early diagnosis: A literature review. *Energies*, 2018, vol. 11, no. 5, art. 1309. doi: 10.3390/en11051309.
15. Xiao C., Liu Z., Zhang T., Zhang X. Deep learning method for fault detection of wind turbine converter. *Applied Sci.*, 2021, vol. 11, no. 3, art. 1280. doi: 10.3390/app11031280.
16. Пальчевский Е.В., Антонов В.В., Еникеев Р.Р. Прогнозирование на основе искусственной нейронной сети второго поколения для поддержки принятия решений в особо значимых ситуациях // Программные продукты и системы. 2022. Т. 35. № 3. С. 384–395. doi: 10.15827/0236-235X.139.384-395.
17. Kumar A., Kumar R. Time-frequency analysis and support vector machine in automatic detection of defect from vibration signal of centrifugal pump. *Measurement*, 2017, vol. 108, pp. 119–133. doi: 10.1016/j.measurement.2017.04.041.
18. Abbasi A.R., Mahmoudi M.R., Avazzadeh Z. Diagnosis and clustering of power transformer winding fault types by cross-correlation and clustering analysis of FRA results. *IET Generation, Transmission & Distribution*, 2018, vol. 12, no. 19, pp. 4301–4309. doi: 10.1049/iet-gtd.2018.5812.

## Developing predictive analytics models for industrial equipment failures

Artem V. Chernukhin <sup>1</sup>✉, Elizaveta A. Bogdanova <sup>2</sup>, Tatiana V. Savitskaya <sup>1</sup>

<sup>1</sup> Mendeleev University of Chemical Technology of Russian, Moscow, 125047, Russian Federation

<sup>2</sup> Lomonosov Moscow State University, Moscow, 119991, Russian Federation

### For citation

Chernukhin, A.V., Bogdanova, E.A., Savitskaya, T.V. (2024) ‘Development of predictive analytics models for industrial equipment failures’, *Software & Systems*, 37(2), pp. 254–261 (in Russ.). doi: 10.15827/0236-235X.142.254-261

### Article info

Received: 31.10.2023

After revision: 11.11.2023

Accepted: 26.12.2023

**Abstract.** The paper describes new approaches to building a model for predictive analytics of industrial equipment failures. The relevance of the study is due to the need to identify failures that lead to a decrease in operating efficiency or downtime of large production lines at an industrial enterprise in advance. The study examines modern approaches, which use machine learning to solve similar problems, and describes their advantages and disadvantages in detail. Data for training models was obtained from PJSC Severstal and include information on sensor readings measuring currents, temperatures, pressure and vibrations for six exhausters over three years. Training and testing involved only technical locations with faults during the analyzed period. Due to the complex relationship between sensor readings and exhauster condition, it was decided to create a predictive model based on “soft voting” between three algorithms with different classification approaches: a convolutional neural network, logistic regression and a support vector machine. The proposed approach is based on the high-level Python programming language using the Anaconda distribution. The paper describes the procedure for performing the research, presents block diagrams of the developed algorithms and their detailed description. The authors carried out comprehensive testing of the developed software that implements the fault prediction model. The study results confirm the performance of the proposed model for predicting failures of equipment technical components, which can be adapted for predictive analytics of failures of a large number of types of industrial equipment at large enterprises in metallurgical, chemical and other industries.

**Keywords:** mathematical modeling, data mining, predictive analytics, machine learning, neural networks, industrial equipment, fault prediction

### References

1. James, A.T., Gandhi, O., Deshmukh, S. (2018) 'Fault diagnosis of automobile systems using fault tree based on digraph modeling', *Int. J. Syst. Assur.*, 9, pp. 494–508. doi: 10.1007/s13198-017-0693-6.
2. Bhakta, K., Sikder, N., Nahid, A.A., Islam, M.M.M. (2019) 'Fault diagnosis of induction motor bearing using Cepstrum-based preprocessing and ensemble learning algorithm', *Proc. Int. Conf. ECCE*, pp. 1–6. doi: 10.1109/ECACE.2019.8679223.
3. Trofimov, V.V. (2017) *Algorithmization and Programming*. Moscow, 137 p. (in Russ.).
4. Okley, P.I. (2017) 'Predicting the residual service life and probability of failure of equipment – base of design of production program of repair works of thermal power plant', *Controlling*, (65), pp. 54–56 (in Russ.).
5. Nan, X., Zhang, B., Liu, C., Gui, Z., Yin, X. (2022) 'Multi-modal learning-based equipment fault prediction in the internet of things', *Sensors*, 22(18), art. 6722. doi: 10.3390/s22186722.
6. Lv, H., Chen, J., Pan, T., Zhang, T., Feng, Y., Liu, Sh. (2022) 'Attention mechanism in intelligent fault diagnosis of machinery: A review of technique and application', *Measurement*, 199, art. 111594. doi: 10.1016/j.measurement.2022.111594.
7. Borovsky, A.S., Shumilina, N.A. (2018) 'Unclear situational network for assessment of the design risk of equipment failure', *Proc. ISA RAS*, 68, pp. 87–93 (in Russ.).
8. Xu, Z., Mei, X., Wang, X., Yue, M., Jin, J., Yang, Y., Li, Ch. (2022) 'Fault diagnosis of wind turbine bearing using a multi-scale convolutional neural network with bidirectional long short term memory and weighted majority voting for multi-sensors', *Renewable Energy*, 182, pp. 615–626. doi: 10.1016/J.RENENE.2021.10.024.
9. Antonov, A.V. (2016) 'Statistical analysis of the nuclear power plant equipment failure data in nonhomogeneous failure flow', *Izv. Vuzov. Yadernaya Energetika*, 3, pp. 20–29. doi: 10.26583/npe.2016.3.03 (in Russ.).
10. Cheng, Y., Yuan, H., Liu, H., Lu, C. (2017) 'Fault diagnosis for rolling bearing based on SIFT-KPCA and SVM', *Eng. Computations*, 34(1), pp. 53–65. doi: 10.1108/EC-01-2016-0005.
11. Mao, W., Feng, W., Liu, Y., Zhang, D., Liang, X. (2021) 'A new deep auto-encoder method with fusing discriminant information for bearing fault diagnosis', *MSSP*, 150, art. 107233. doi: 10.1016/j.ymsp.2020.107233.
12. Ivanov, V.K., Vinogradova, N.V., Palyukh, B.V., Sotnikov, A.N. (2018) 'Modern directions of development and areas of application of the Dempster-Shafer theory', *Artificial Intelligence and Decision Making*, (4), pp. 32–42 (in Russ.). doi: 10.14357/20718594180403.
13. Javed, K., Gouriveau, R., Zerhouni, N. (2017) 'State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels', *MSSP*, 94(9), pp. 214–236. doi: 10.1016/j.ymsp.2017.01.050.
14. Hossain, M., Abu-Siada, A., Muyeen, S. (2018) 'Methods for advanced wind turbine condition monitoring and early diagnosis: A literature review', *Energies*, 11(5), art. 1309. doi: 10.3390/en11051309.
15. Xiao, C., Liu, Z., Zhang, T., Zhang, X. (2021) 'Deep learning method for fault detection of wind turbine converter', *Applied Sci.*, 11(3), art. 1280. doi: 10.3390/app11031280.
16. Palchevsky, E.V., Antonov, V.V., Enikeev, R.R. (2022) 'Forecasting based on a second-generation artificial neural network to support decision-making in critical situations', *Software & Systems*, 35(3), pp. 384–395 (in Russ.). doi: 10.15827/0236-235X.139.384-395.
17. Kumar, A., Kumar, R. (2017) 'Time-frequency analysis and support vector machine in automatic detection of defect from vibration signal of centrifugal pump', *Measurement*, 108, pp. 119–133. doi: 10.1016/j.measurement.2017.04.041.
18. Abbasi, A.R., Mahmoudi, M.R., Avazzadeh, Z. (2018) 'Diagnosis and clustering of power transformer winding fault types by cross-correlation and clustering analysis of FRA results', *IET Generation, Transmission & Distribution*, 12(19), pp. 4301–4309. doi: 10.1049/iet-gtd.2018.5812.

### Авторы

**Чернухин Артем Валерьевич**<sup>1</sup>,  
аспирант, chernukhin.a.v@muctr.ru  
**Богданова Елизавета Александровна**<sup>1</sup>,  
аспирант, eabogdanova.bioinf@gmail.com  
**Савицкая Татьяна Вадимовна**<sup>1</sup>,  
д.т.н., профессор, savitskaia.t.v@muctr.ru

### Authors

**Artem V. Chernukhin**<sup>1</sup>, Postgraduate Student,  
chernukhin.a.v@muctr.ru  
**Elizaveta A. Bogdanova**<sup>2</sup>, Postgraduate Student,  
eabogdanova.bioinf@gmail.com  
**Tatiana V. Savitskaya**<sup>1</sup>, Dr.Sc. (Engineering),  
Professor, savitskaia.t.v@muctr.ru

<sup>1</sup> Российский химико-технологический университет имени Д.И. Менделеева, г. Москва, 125047, Россия

<sup>2</sup> Московский государственный университет имени М.В. Ломоносова, г. Москва, 119991, Россия

<sup>1</sup> Mendeleev University of Chemical Technology of Russian, Moscow, 125047, Russian Federation  
<sup>2</sup> Lomonosov Moscow State University, Moscow, 119991, Russian Federation