

УДК 004.852

DOI: [10.26102/2310-6018/2023.43.4.028](https://doi.org/10.26102/2310-6018/2023.43.4.028)

## Разработка алгоритма подбора модели анализа данных для прогнозирования работоспособности промышленных роботов

А.С. Гончаров<sup>✉</sup>, А.О. Савельев, А.С. Писанкин, А.Ю. Чепкасов

*Томский политехнический университет, Томск, Российская Федерация*

**Резюме.** В связи с интенсивным темпом развития систем сбора, накопления и анализа данных разрабатывается все больше методов, подходов и систем для принятия решений в области предиктивного обслуживания в современных роботизированных производствах с целью увеличения производительности и эффективности использования временных, финансовых и материальных ресурсов. Процесс технического обслуживания основных средств производства является одним из ключевых для обеспечения безопасного, эффективного и непрерывного производства. Современное оборудование оснащено множеством систем мониторинга, самодиагностики и интеллектуальных датчиков, позволяющих осуществлять сбор значительного объема первичных данных, которые могут содержать полезные знания. В статье представлен подход по разработке алгоритма подбора моделей машинного обучения при анализе данных о работе промышленных манипуляторов в рамках процесса предиктивного обслуживания. Разработанный алгоритм позволяет сократить временные издержки на обучение моделей анализа данных (в том числе машинного обучения и искусственных нейронных сетей) за счет подбора массивов данных, собранных с парка оборудования (на примере промышленных роботов), которые имеют наибольшую степень подобия относительно данных собранных с единичного оборудования, что позволяет избежать обучение дополнительных моделей анализа данных, при удовлетворительных результатах тестирования. Сбор данных производился с четырех разных промышленных роботов; для анализа использованы методы: линейная модель, сверточная нейронная сеть, многослойный перцептрон; для оценки степени подобия использован алгоритм динамической трансформации временной шкалы.

**Ключевые слова:** предиктивная аналитика, прогнозирование работоспособности, машинное обучение, промышленный робот, системный анализ.

**Благодарности:** исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-37-90113.

**Для цитирования:** Гончаров А.С., Савельев А.О., Писанкин А.С., Чепкасов А.Ю. Разработка алгоритма подбора модели анализа данных для прогнозирования работоспособности промышленных роботов. *Моделирование, оптимизация и информационные технологии.* 2023;11(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1437> DOI: 10.26102/2310-6018/2023.43.4.028

## Algorithm for selecting data analysis model for predicting the performance of industrial robots

A.S. Goncharov<sup>✉</sup>, A.O. Savelev, A.S. Pisankin, A.Y. Chepkasov

*Tomsk Polytechnic University, Tomsk, the Russian Federation*

**Abstract.** Due to the intensive pace of development of systems for data collection, accumulation and analysis, more and more methods, approaches and systems are being created for decision-making in the field of predictive maintenance in modern robotic industries in order to increase productivity and efficiency of resource use (time, finances and material resources). Maintaining fixed assets of production is crucial to ensuring safe, efficient and continuous production. Modern equipment is fitted with a variety of monitoring systems, self-diagnosis and intelligent sensors that allow collecting a significant amount of primary data that may contain useful knowledge. The article presents an approach to developing an

algorithm for selecting machine learning models when analyzing data on the performance of industrial manipulators as part of the predictive maintenance process. The developed algorithm makes it possible to reduce the time spent on training data analysis models (including machine learning and artificial neural networks) by selecting arrays of data collected from a fleet of equipment (for example, industrial robots) that have the greatest degree of similarity relative to the data collected from single equipment; this helps to avoid training additional data analysis models with satisfactory test results. Data was collected from four different industrial robots. The following methods were used for the analysis: linear model, convolutional neural network, multilayer perceptron. The algorithm of dynamic transformation of the timeline was used to assess the degree of similarity.

**Keywords:** predictive analytics, performance forecasting, machine learning, industrial robot, system analysis.

**Acknowledgments:** the reported study was funded by the RFBR, project number 20-37-90113.

**For citation:** Goncharov A.S., Savelev A.O., Pisankin A.S., Chepkasov A.Y. Algorithm for selecting data analysis model for predicting the performance of industrial robots. *Modeling, Optimization and Information Technology*. 2023;11(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1437> DOI: 10.26102/2310-6018/2023.43.4.028 (In Russ.).

## Введение

Своевременное определение состояния оборудования и его техническое обслуживание было и остается важной задачей на любом производстве. Переход к концепции Индустрии 4.0 и цифровых фабрик приводит к тому, что при работе оборудования сохраняются огромные объемы данных [1]. Обслуживание современных сложных технических систем требует значительных материальных затрат. Актуальной остается задача по обеспечению безотказного функционирования промышленного оборудования при минимизации затрат на его содержание и техническое обслуживание. Принятие решений при техническом обслуживании основывается на извлечении и получении новых знаний, извлекаемых из низкоуровневых данных [2, 3]. Современные исследования применения интеллектуальных методов анализа данных для решения задач по прогнозированию работоспособности и отказов промышленного оборудования лежат в рамках подходов по проактивному, предиктивному техническому обслуживанию [4]. При проактивном обслуживании анализ данных может предсказать потенциальные неисправности и износ оборудования, что позволяет проводить заранее плановые работы и избегать аварий. Основным преимуществом предиктивного подхода является прогнозирование остаточного ресурса оборудования (определение оптимальных интервалов обслуживания и эксплуатации), что позволяет гибко корректировать стратегию обслуживания и оптимизировать расходы. Оптимизация расходов позволяет сократить издержки на закупку запасных частей, топлива и других материалов, необходимых для обслуживания. Данные подходы позволяют осуществить переход от планового обслуживания к обслуживанию на основе данных о прогнозном состоянии оборудования и отдельных его составляющих или остаточного полезного рабочего ресурса. Эксплуатация однотипного оборудования позволяет использовать накопленную информацию не только для анализа технико-экономических показателей эффективности, но и для разработки систем автоматического определения предаварийных состояний и формирования программных модулей для интеграции в систему управления линией производства [5]. В процессе управления системами, основанными на анализе данных, обозначаются дополнительные аспекты оперирования данными и организацией архитектуры использования моделей, которые требуют тщательной проработки. Такими аспектами являются: ориентир на трудно оптимизируемые бизнес-параметры, эффективное обслуживание моделей машинного

обучения, проблемы интеграции специфических данных. Проблема заключается в том, что эксплуатация систем машинного обучения зависит от принимаемых данных, которые могут измениться из-за изменений условий производственного процесса, нормативных документов, человеческого фактора операционного персонала, ошибок в «конвейерах» передачи данных или состязательных атак, приводящих к неверному решению [6, 7].

### Техническое обслуживание на основе данных

Последовательность операций процесса технического обслуживания, основанного на оценке состояния при помощи использования методов анализа данных, представляется следующим образом:

1. Реализация сбора данных с устройств программно-аппаратного типа, включающих в себя датчики, контроллеры и системы мониторинга, осуществляется путем получения первичных данных без их предварительной обработки.

2. Агрегация и предварительная обработка данных в системах хранения; создание пространства признаков:

- 2.1. Моделирование данных.
- 2.2. Извлечение признаков.
- 2.3. Определение целевых показателей.
- 2.4. Фильтрация признаков [8].

3. Использование алгоритмов анализа данных с целью осуществления процедуры классификации отказов технического оборудования.

- 3.1. Выбор алгоритма.
- 3.2. Планирование тестирования.
- 3.3. Итеративное обучение модели.
- 3.4. Оценка и анализ результатов.

4. Управление техническим обслуживанием с учетом классификации отказов и регламентом обслуживания.

5. Стратегическое планирование и модификация расписания регулярного технического обслуживания промышленного оборудования.

6. Определение процедур технического обслуживания производственного оборудования, соответствующих скорректированному плану.

Системы, работающие на основе данных, легко масштабируются и адаптируются под изменяющиеся условия или требования бизнеса. Подход предиктивного обслуживания позволяет перейти от реактивного и планового технического обслуживания. Для реализации такого рода подхода используются различные статистические методы, математические модели (в том числе машинное обучение и искусственные нейронные сети), осуществляющие анализ больших массивов исторических данных с целью оценки текущего и остаточного ресурса агрегатов оборудования [9-11]. Данный подход позволяет значительно удешевить обслуживание и ремонт оборудования, уменьшить количество аварийных ситуаций, и, как следствие избежать незапланированных простоев, что повышает ресурсоэффективность системы в целом. Результаты, получаемые в рамках предиктивного обслуживания, используются для процесса принятия решений о целесообразности планирования и корректировки стратегии технического обслуживания на основе подсчета экономической выгоды, показывающей полезность или бесполезность получаемого экономического эффекта на основе оценки накопленных данных. Таким образом, техническое обслуживание на основе данных предоставляет ряд значительных преимуществ, которые могут существенно повлиять на эффективность и конкурентоспособность бизнеса.

### Цели настоящего исследования

1. Исследование методов и подходов анализа данных в рамках предиктивного технического обслуживания промышленного оборудования.
2. Проектирование и разработка программного обеспечения, реализующего ограничения исследуемого процесса по анализу данных.
3. Разработка алгоритма подбора модели анализа данных (машинного обучения и искусственной нейронной сети) о работе оборудования (на примере промышленных роботов) с использованием методов оценки подобия данных.
4. Тестирование моделей на примере задачи прогнозирования целевого параметра (измеренной температуры) электропривода.

### Основные методы решения

1. Метрики оценки машинного обучения: среднеквадратичная ошибка, точность.
2. Методы, использованные для оценки подобия: метод k-средних (гибкий метод, не чувствительный к выбросам и не требующий предположений об изначальном распределении данных), алгоритм динамической трансформации временной шкалы (является улучшение алгоритма Евклидова расстояния за счет учета сдвигов временной шкалы).

Для анализа данных методами машинного обучения и ИНС использованы:

- линейная модель;
- рекуррентная нейронная сеть;
- многослойный перцептрон.

### Проектирование программного обеспечения

Для реализации систем поддержки принятия решений планирования технического обслуживания и оценки состояния необходимо следующее наличие составляющих:

- 1) подсистема сбора данных: обеспечение доступа к получению информации с цифровых датчиков, преобразователей данных, контроллеров и систем мониторинга промышленного оборудования с последующим коллекционированием и сохранением массивов данных в системах хранения;
- 2) подсистема управления данными: алгоритмическое обеспечение для доступа к массиву собранных данных – выделение отдельных признаков, свойств и формирование выборок;
- 3) подсистема мониторинга состояния: обеспечение мониторинга текущего состояния оборудования (в течение рабочего цикла) – сравнение данных мониторинга с ожидаемыми значениями или пороговыми значениями; использование обратной связи в виде сигналов и индикаторов состояния для оповещения операционного персонала;
- 4) подсистема оценки работоспособности промышленного оборудования: обеспечение анализа тренда на уменьшение срока полезной эксплуатации, основываясь на исторических данных работы, текущего состояния и журнала технического обслуживания;
- 5) подсистема прогностической оценки: обеспечение оценки будущего состояния работоспособности оборудования на основе данных системы оценки работоспособности и оценки будущих сценариев использования;
- 6) подсистема поддержки принятия решений: обеспечение рекомендаций для планирования технического обслуживания и настройке конфигурации производственного оборудования с учетом исторических данных эксплуатации, текущих

и будущих сценариев использования и ограничениями по обеспечению ресурсами для работы и обслуживания.

Проектирование и разработка программного обеспечения осуществляется с учетом ограничений, выявленных в результате анализа процесса принятия решений о планировании технического обслуживания на основе анализа данных. Эффективность применения моделей интеллектуального анализа для прогнозирования работоспособности и состояния оборудования оценивается на этапе тестирования и этапе валидации. Тестирование моделей производится при помощи метрик – вычисляемая величина в числовом выражении, на основе которой можно оценить: точность, полноту, ошибку, долю положительных исходов классификации или регрессии. Метрики выступают в роли обратной связи для управления жизненным циклом модели от выбора параметров и гиперпараметров до итеративного процесса обучения и дообучения. Помимо метрик на точность обучения модели и оптимизацию ресурсов при обучении и тестировании влияет набор данных, то есть количество признаков, характеризующих выборку. В рамках настоящей работы использован гибридный подход по отбору признаков – методы фильтрации (корреляция Пирсона, дисперсия) и методы обертки (метод последовательного отбора признаков). Задача выбора гиперпараметров обучения заключается в подборе таких параметров, при которых заданная модель выбранного алгоритма обучения будет наиболее эффективна.

### **Разработка алгоритма подбора модели**

Алгоритмическая модель по подбору модели машинного обучения включает в себя два основных блока:

#### **1. Конструирование базовой модели на обучающей выборке:**

1.1. Получение массива данных о процессе работы единицы промышленного оборудования; подготовка массива данных: нормализация, рандомизация, отбор значимых параметров, разбиение на обучающую и тестовую выборку.

1.2. Выбор метода и настройка параметров обучения модели для поставленной задачи.

1.3. Тестирование метрик модели; валидация результатов прогнозирования для оценки решения поставленной задачи.

1.4. На основе результатов пункта 1.3: настройка параметров и гиперпараметров модели.

#### **2. Рекомендация к выбору обученной модели для тестовой выборки:**

2.1. Получение массива данных о процессе работы единицы промышленного оборудования; подготовка массива данных: нормализация, рандомизация, отбор значимых параметров.

2.2. Вычисление оценки сходства между тестовой выборкой и обучающей из пункта 1.1; определение порогового значения меры сходства [12].

2.3. Тестирование базовой модели, обученной на выборке из пункта 1.1 на тестовой выборке, при прохождении определенного порога сходства.

2.4. Оценка метрик и вывод о применимости модели для прогнозирования данных для тестовой выборки.

На первом этапе решения задачи подбора моделей машинного обучения на основе оценки сходства данных предлагается кластеризовать экспериментальные данные при помощи алгоритма k-средних. Далее вычисляются расстояния между получившимися кластерами методом оценки подобия данных. Разработанный алгоритм состоит из следующих этапов:

1. После отбора значимых признаков производится оценка подобию имеющихся и подготовленных к анализу наборов данных.

2. Кластеризация наборов данных – для нахождения кластеров методов k-средних и вычисление расстояния между центроидами кластеров методами оценки подобию данных.

3. Поиск ближайшего к центроиду кластера набора данных – в полученных кластерах осуществляется поиск ближайшего к центроиду кластера набора данных, на основе которого строится эталонная для данного кластера модель машинного обучения.

4. Построение модели машинного обучения – выбранные наборы данных используются для построения моделей машинного обучения методами: линейная регрессия, многослойный персептрон и рекуррентная ИНС (RNN).

После осуществления вышеперечисленных шагов на выходе получают обученные модели машинного обучения («эталонные») с соответствующими им наборами данных, находящимися на наименьшем расстоянии к центроиду кластера. Далее производится тестирование модели машинного обучения на отобранных наборах данных, отсортированных по уменьшению меры подобию (то есть по увеличению расстояния между центроидами полученных кластеров). Если ошибка превышает 50 %, то активируется алгоритм кластеризации с измененными параметрами. На следующем этапе используются эталонные модели и соответствующие выборки для аналогичных наборов данных. Предложенный метод включает в себя:

1) оценку схожести временных рядов – производится сравнение входных данных с эталонными моделями (используя Евклидово расстояние, методы трансформации времени);

2) определение кластера – производится определение конкретного кластера, к которому относится входной набор данных, где расстояние до центроида кластера минимально;

3) применение модели машинного обучения – исходные данные используются как входной параметр для соответствующей эталонной модели.

Если временной ряд не соответствует ни одному из кластеров, процесс возвращается к начальному этапу и формируется новый кластер.

## Результаты

Экспериментальная апробация предлагаемого алгоритма прогнозирования отказов была выполнена на основе задачи прогнозирования температуры привода промышленного робота. Правильное и своевременное прогнозирование температуры электропривода позволяет: предотвращать его перегрев, оптимизировать работу и повысить энергоэффективность, определение оптимального момента для обслуживания или замены. Данные были получены в результате сбора при процессе выполнения однотипных операций на протяжении большого промежутка времени (более 7 часов непрерывной работы).

Анализируемый набор данных состоит из четырех датасетов. Каждый датасет содержит исторические данные о работе промышленного робота, каждый из которых суммарно выполнял однотипную рабочую операцию (перемещение паллеты, работа со сварочным агрегатом, фрезерование поверхности) на протяжении 40 часов. Количество строк данных каждого датасета примерно 180 000 строк. Для разбиения данных на обучающую и тестовую выборку выбраны пропорции 70:30 с применением рандомизации. График температуры каждого из электроприводов робота колеблется в определенном диапазоне (от 290 до 340 градусов по Кельвину), в начале работы резко увеличиваясь и выходя на плато после 3-4 часов работы. Для сглаживания временного

ряда дополнительно применен метод аппроксимации. На Рисунке 1 представлены результаты тестирования 4-х наборов данных с разных единиц оборудования; на графике представлена зависимость точности прогнозирования целевого признака (каждой из трех используемых моделей) в зависимости от степени подобия данных по отношению к обучающей выборке на основе применения метода динамической трансформации временной шкалы (DTW). По горизонтальной оси указана мера подобия, которая рассчитывается как расстояние между центроидами кластеров из наборов данных. По вертикальной оси указана точность прогнозирования в процентах, которая рассчитывается как количество верно предсказанных значений температуры, попадающих в интервал  $\pm 0,5$  градусов по Кельвину.

Наборы данных содержат следующие признаки: время, номер электропривода, сила тока (мА), измеренная скорость вращения (м/с), температура электропривода (К), момент силы (Н\*м), заданная программой скорость вращения (м/с). Для отбора значимых признаков были применены методы: фильтрации (оценка среднеквадратичного отклонения числового признака) и обертки (последовательный отбор признаков). Для прогнозирования отобраны следующие признаки: скорость вращения и сила тока. Выбор методов обусловлен малым набором признаков.

Результаты прогнозирования (линейная модель, «original» – измеренные данные, «agilus» – результат прогнозирования параметра на тестовом датасете обучающей выборки, «svarka» – тестируемый датасет, собранный с другой единицы оборудования) наиболее подходящей модели (по критерию подобия данных методом DTW) представлены на Рисунке 2.

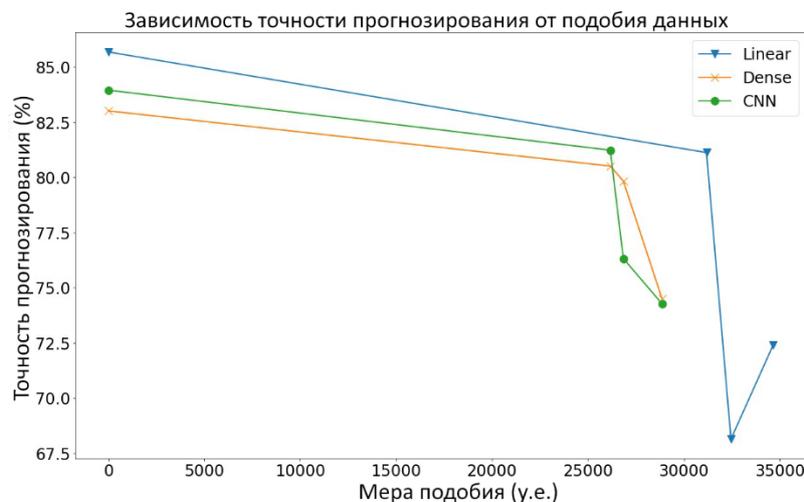


Рисунок 1 – Зависимость точности модели от подобия данных (на примере анализа данных с робота «agilus»)

Figure 1 – Dependence of the model accuracy on the similarity of data (using the example of data analysis from the robot “agilus”)

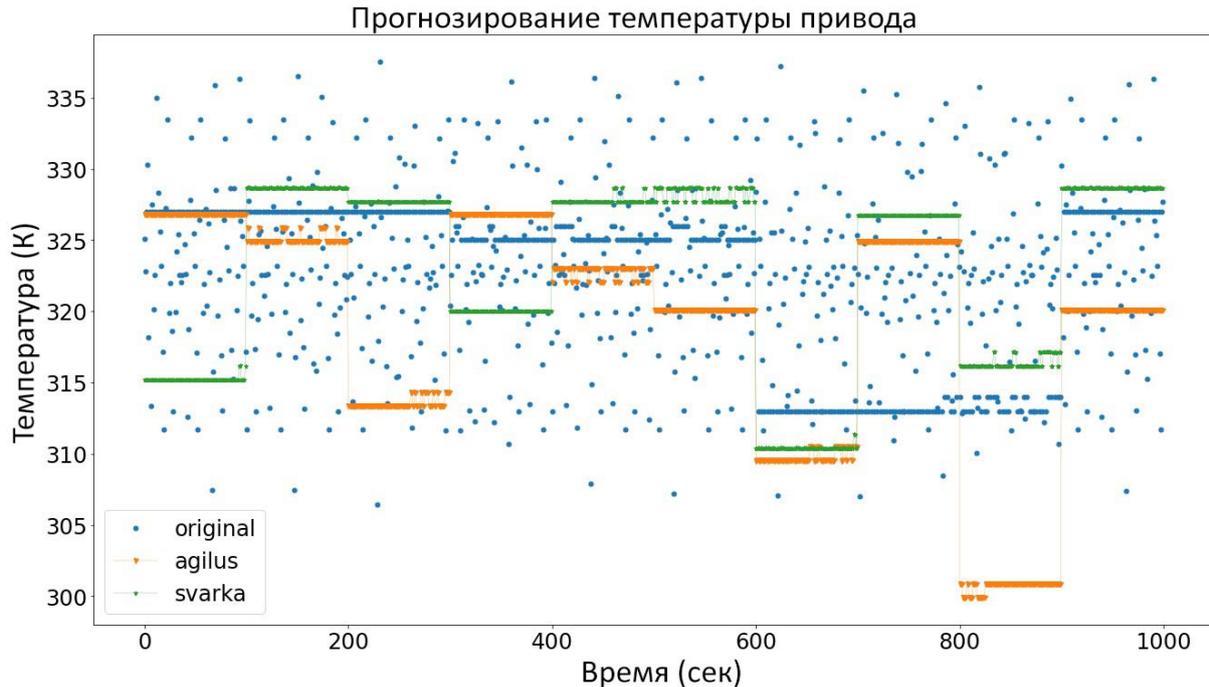


Рисунок 2 – Зависимость точности модели от подобию данных на примере прогнозирования линейной моделью температуры привода на роботе «svarka»

Figure 2 – Dependence of model accuracy on the similarity of data using the example of forecasting the drive temperature by a linear model for the robot “svarka”

На основе полученных данных манипулятор «agilus» в большинстве случаев показывает наивысший процент точности, когда в качестве тестовой выборки для модели берется близкий по алгоритмам сходимости манипулятор «svarka». Точность предсказания состояния промышленного манипулятора с использованием моделей, подобранных алгоритмом адаптивного выбора моделей машинного обучения ниже, чем при использовании модели, обученной на исходном наборе данных. В Таблице 1 представлены оценки подобию выборок при использовании алгоритма «DTW».

Таблица 1 – Оценка подобию данных методом DTW  
Table 1 – Estimation of data similarity by DTW method

Подобие данных	<b>agilus</b>	<b>svarka</b>	<b>palitir</b>	<b>frezer</b>
<b>agilus</b>	-	31187	34662	32463
<b>svarka</b>	-	-	54706	51315
<b>palitir</b>	-	-	-	53119
<b>frezer</b>	-	-	-	-

Три модели анализа данных были подвергнуты обучению на различных наборах данных. Сформированные модели были протестированы для оценки точности предсказаний на данных, полученных от других манипуляторов. Для каждой модели точность была вычислена несколько раз, после чего было вычислено среднее значение полученных результатов в процентах. В результате была составлена таблица, в которой представлены усредненные значения точности для каждой модели (Таблица 2). Описание итоговых моделей анализа данных:

1) линейная модель – модель с одним слоем (реализуется через программную библиотеку «Keras»; функция потерь – среднеквадратичная ошибка; оптимизатор – «Adam»; метрика – средняя абсолютная ошибка; количество эпох – 20);

2) многословный перцептрон – модель с двумя скрытыми слоями по 64 нейрона и одним выходным нейроном (реализуется через программную библиотеку «Keras»; функция потерь – среднеквадратичная ошибка; оптимизатор – «Adam»; метрика – средняя абсолютная ошибка; активатор слоя – «gelu»; количество эпох – 20);

3) рекуррентная нейронная сеть – модель с одним скрытым слоем долговременной краткосрочной памяти (LSTM) размером в 32 нейрона (реализуется через программную библиотеку «Keras»; функция потерь – среднеквадратичная ошибка; оптимизатор – «Adam»; метрика – средняя абсолютная ошибка; количество эпох – 20).

Таблица 2 – Таблица точностей прогнозирования обученных моделей

Table 2 – Trained models accuracy prediction

Обучающая/тестовая	<b>agilus</b>	<b>svarka</b>	<b>palitir</b>	<b>frezer</b>
<b>Linear (линейная модель)</b>				
<b>agilus</b>	85,68	81,12	72,40	68,14
<b>svarka</b>	74,45	79,63	70,61	70,47
<b>palitir</b>	75,46	81,65	86,93	74,06
<b>frezer</b>	77,91	70,95	74,77	79,01
<b>Dense (многослойный перцептрон)</b>				
<b>agilus</b>	83,01	80,51	74,50	79,83
<b>svarka</b>	75,74	80,75	72,96	72,57
<b>palitir</b>	77,32	81,71	73,28	73,91
<b>frezer</b>	73,16	80,43	75,37	71,73
<b>RNN (рекуррентная нейронная сеть)</b>				
<b>agilus</b>	83,95	81,23	74,27	76,32
<b>svarka</b>	79,21	82,78	77,15	70,81
<b>palitir</b>	71,83	79,51	80,14	72,84
<b>frezer</b>	80,45	72,11	79,32	75,68

### Заключение

Разработан алгоритм подбора модели машинного обучения и ИНС на основе вычисления коэффициентов сходства данных между выборками, собранными с разных промышленных роботов. Спроектирована и разработана архитектура программного обеспечения для управления массивами данных о работе промышленных роботов и моделями интеллектуального анализа данных, с реализацией функции рекомендации модели на основе оценки подобия данных алгоритмом динамической трансформации временной шкалы. Использование реализованного алгоритма на данных, собранных с четырех разных промышленных роботов, показывает сокращение временных ресурсов на обучение новой модели для отдельной выборки и прогнозирования параметров работы в среднем на 60-70%, при потерях точности в процессе тестирования от 5% до 20% (при доверительном интервале  $\pm 0.5$  градусов по Кельвину). Практическая значимость разработанного алгоритма состоит в улучшении процесса управления моделями анализа данных с разнородного парка промышленного оборудования за счет подбора уже обученных моделей, подходящих для решения поставленных задач по прогнозированию работоспособности и ранних отказов. Подбор и дообучение рабочих моделей на данных, обладающих наибольшей степенью подобия, позволяет сократить

вычислительные и временные ресурсы на обучение новых моделей анализа данных. В дальнейшей работе планируется исследовать возможность применения метода автоматического машинного обучения для оптимизации процесса тестирования и выбора модели анализа.

### СПИСОК ИСТОЧНИКОВ

1. Mohammadi N., Taylor J. Knowledge discovery in smart city digital twins. *Proceedings of the 53rd Hawaii International Conference on System Sciences*. 2020. DOI: 10.24251/HICSS.2020.204.
2. Bodo R., Bertocco M., Bianchi A. Fault classification driven by maintenance management for smart maintenance applications. *2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT*. 2020;27–32. DOI: 10.1109/MetroInd4.0IoT48571.2020.9138294.
3. Ortiz G., Caravaca J.A., Garcia-de-Prado A. et al. Real-time context-aware microservice architecture for predictive analytics and smart decision-making. *IEEE Access*. 2019;7:183177–183194. DOI: 10.1109/ACCESS.2019.2960516.
4. Silvestrin L.P., Hoogendoorn M., Koole G. A comparative study of state-of-the-art machine learning algorithms for predictive maintenance. *2019 IEEE Symposium Series on Computational Intelligence (SSCI)*. 2019;760–767. DOI: 10.1109/SSCI44817.2019.9003044.
5. Raja H.A., Asad B., Vaimann T. et al. Custom simplified machine learning algorithms for fault diagnosis in electrical machines. *2022 International Conference on Diagnostics in Electrical Engineering (Diagnostics)*. 2022;1–4. DOI: 10.1109/Diagnostics55131.2022.9905174.
6. Schelter S., Biesmann F., Januschowski T. et al. On challenges in machine learning model management. *IEEE Data Engineering Bulletin*. 2015.
7. Ashmore R., Calinescu R., Paterson C. Assuring the machine learning lifecycle: Desiderata, methods, and challenges. *ACM Computing Surveys (CSUR)*. 2021;54(5):1–39. DOI: 10.1145/3453444.
8. Naing Y.T., Raheem M., Batcha N.K. Feature selection for customer churn prediction: a review on the methods & techniques applied in the Telecom industry. *2022 IEEE International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*. 2022;1–5. DOI: 10.1109/ICDCECE53908.2022.9793315.
9. Dsouza J., Velan S. Preventive maintenance for fault detection in transfer nodes using machine learning. *2019 International conference on computational intelligence and knowledge economy (ICCIKE)*. 2019;401–404. DOI: 10.1109/ICCIKE47802.2019.9004230.
10. Singh P., Agrawal S., Chakraborty A. Multi-Classifer Predictive Maintenance Strategy for a Manufacturing Plant. *2021 International Conference on Maintenance and Intelligent Asset Management (ICMIAM)*. 2021;1–4. DOI: 10.1109/ICMIAM54662.2021.9715224.
11. Chianese R., Cicala L., Angelino C.V. et al. A Risk and Priority Model for Cost-Benefit Analysis and Work Scheduling within Predictive Maintenance Scenarios. *2021 26th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*. 2021;1–4.
12. Алимова И.С., Соловьев В.Д., Батыршин И.З. Сравнительный анализ мер сходства, основанных на преобразовании скользящих аппроксимаций, в задачах классификации временных рядов. *Труды Института системного программирования РАН*. 2016;28(6):207–222. DOI: 10.15514/ISPRAS-2016-28(6)-15.

## REFERENCES

1. Mohammadi N., Taylor J. Knowledge discovery in smart city digital twins. *Proceedings of the 53rd Hawaii International Conference on System Sciences*. 2020. DOI: 10.24251/HICSS.2020.204.
2. Bodo R., Bertocco M., Bianchi A. Fault classification driven by maintenance management for smart maintenance applications. *2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT*. 2020;27–32. DOI: 10.1109/MetroInd4.0IoT48571.2020.9138294.
3. Ortiz G., Caravaca J.A., Garcia-de-Prado A. et al. Real-time context-aware microservice architecture for predictive analytics and smart decision-making. *IEEE Access*. 2019;7:183177–183194. DOI: 10.1109/ACCESS.2019.2960516.
4. Silvestrin L.P., Hoogendoorn M., Koole G. A comparative study of state-of-the-art machine learning algorithms for predictive maintenance. *2019 IEEE Symposium Series on Computational Intelligence (SSCI)*. 2019;760–767. DOI: 10.1109/SSCI44817.2019.9003044.
5. Raja H.A., Asad B., Vaimann T. et al. Custom simplified machine learning algorithms for fault diagnosis in electrical machines. *2022 International Conference on Diagnostics in Electrical Engineering (Diagnostika)*. 2022;1–4. DOI: 10.1109/Diagnostika55131.2022.9905174.
6. Schelter S., Biesmann F., Januschowski T. et al. On challenges in machine learning model management. *IEEE Data Engineering Bulletin*. 2015.
7. Ashmore R., Calinescu R., Paterson C. Assuring the machine learning lifecycle: Desiderata, methods, and challenges. *ACM Computing Surveys (CSUR)*. 2021;54(5):1–39. DOI: 10.1145/3453444.
8. Naing Y.T., Raheem M., Batcha N.K. Feature selection for customer churn prediction: a review on the methods & techniques applied in the Telecom industry. *2022 IEEE International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*. 2022;1–5. DOI: 10.1109/ICDCECE53908.2022.9793315.
9. Dsouza J., Velan S. Preventive maintenance for fault detection in transfer nodes using machine learning. *2019 International conference on computational intelligence and knowledge economy (ICCIKE)*. 2019;401–404. DOI: 10.1109/ICCIKE47802.2019.9004230.
10. Singh P., Agrawal S., Chakraborty A. Multi-Classifer Predictive Maintenance Strategy for a Manufacturing Plant. *2021 International Conference on Maintenance and Intelligent Asset Management (ICMIAM)*. 2021;1–4. DOI: 10.1109/ICMIAM54662.2021.9715224.
11. Chianese R., Cicala L., Angelino C.V. et al. A Risk and Priority Model for Cost-Benefit Analysis and Work Scheduling within Predictive Maintenance Scenarios. *2021 26th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*. 2021;1–4.
12. Alimova I.S., Solovev V.D., Batyrshin I.Z. Comparative analysis of similarity measures based on the transformation of sliding approximations in time series classification problems. *Proceedings of the Institute of System Programming of the Russian Academy of Sciences*. 2016;28(6):207–222. DOI: 10.15514/ISPRAS-2016-28(6)-15. (In Russ.).

## ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT AUTHORS

**Гончаров Аркадий Сергеевич**, ассистент отделения информационных технологий Инженерной школы информационных технологий и робототехники, Томский политехнический университет, Томск, Российская Федерация.  
*email:* [asg19@tpu.ru](mailto:asg19@tpu.ru)

**Arkady S. Goncharov**, Assistant at the School of Computer Science & Robotics, Department of Information Technology, Tomsk Polytechnic University, Tomsk, the Russian Federation.

**Савельев Алексей Олегович**, кандидат технических наук, доцент отделения информационных технологий Инженерной школы информационных технологий и робототехники, Томский политехнический университет, Томск, Российская Федерация.  
*email:* [sava@tpu.ru](mailto:sava@tpu.ru)

**Aleksey O. Savelev**, Candidate of Technical Sciences, Assistant Professor at the School of Computer Science & Robotics, Department of Information Technology, Tomsk Polytechnic University, Tomsk, the Russian Federation.

**Андрей Сергеевич Писанкин**, магистрант отделения информационных технологий Инженерной школы информационных технологий и робототехники, Томский политехнический университет, Томск, Российская Федерация.  
*email:* [asp66@tpu.ru](mailto:asp66@tpu.ru)

**Andrey S. Pisankin**, Master's Student, the School of Computer Science & Robotics, Department of Information Technology Tomsk Polytechnic University, Tomsk, the Russian Federation.

**Артём Юрьевич Чепкасов**, магистрант отделения информационных технологий Инженерной школы информационных технологий и робототехники, Томский политехнический университет, Томск, Российская Федерация.  
*email:* [ayc1@tpu.ru](mailto:ayc1@tpu.ru)

**Artem Y. Chepkasov**, Master's Student at the School of Computer Science & Robotics, Department of Information Technology Tomsk Polytechnic University, Tomsk, the Russian Federation.

*Статья поступила в редакцию 28.11.2023; одобрена после рецензирования 20.12.2023; принята к публикации 25.12.2023.*

*The article was submitted 28.11.2023; approved after reviewing 20.12.2023; accepted for publication 25.12.2023*