

УДК 004.852

DOI: 10.22213/2410-9304-2025-1-82-93

## Определение технического состояния и прогнозирование остаточного ресурса электропривода в предсказательном обслуживании: обзор зарубежных источников

П. А. Санников, аспирант, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

П. В. Лекомцев, кандидат технических наук, доцент, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

*Предсказательное обслуживание электропривода в составе технологического оборудования позволяет снизить вероятность внепланового простоя производства и минимизировать затраты на его ремонт путем непрерывного мониторинга состояния и прогнозирования остаточного ресурса электропривода. В статье на основе анализа зарубежных источников и стандартов ИСО представлены аспекты систем предсказательного обслуживания электропривода: рассмотрены этапы их построения и методы, применяющиеся на каждом этапе. Сделан акцент на наиболее трудоемкие и сочетающие в себе различные методы этапы – диагностику состояния электропривода и прогнозирование его остаточного ресурса. Выделены методы определения технического состояния электропривода, рассмотрены их преимущества и недостатки, а также типы неисправностей, которые возможно диагностировать с помощью каждого из методов. Показано, что наибольшую эффективность и широкое применение демонстрируют методы, основанные на анализе вибрационных и электрических сигналов. Они позволяют выявлять широкий спектр неисправностей и применимы для оценки технического состояния практически всех типов электродвигателей. Проведен сравнительный анализ методов машинного обучения, применяемых для прогнозирования неисправностей и остаточного ресурса электропривода. Отмечены такие методы машинного обучения, как метод случайного леса, нейронные сети долгой краткосрочной памяти, метод опорных векторов, метод  $k$ -ближайших соседей. Анализ показал, что выбор алгоритма зависит от множества факторов и не может основываться на универсальных подходах.*

**Ключевые слова:** предсказательное обслуживание, определение технического состояния, диагностика, электропривод, глубокое обучение, методы классификации и регрессии.

### Введение

Одним из ключевых направлений в повышении эффективности и снижении затрат на обслуживание оборудования современных промышленных предприятий является предсказательное обслуживание (predictive maintenance, PdM). Данный подход позволяет прогнозировать и предотвращать возможные поломки оборудования, тем самым сокращая простои производства и расходы на ремонт [1].

Методология технического обслуживания, в том числе предсказательного, основана на теории надежности и технической диагностики сложных систем. Теория надежности позволяет оценивать вероятность отказа системы в различных условиях эксплуатации. На основе этой теории разрабатываются модели, позволяющие предсказывать срок службы компонентов и систем в целом. С развитием вычислительных технологий и сбора больших объемов данных стало возможным применять аналитические методы для выявления закономерностей, приводящих к отказам. Техническая диагностика, в свою очередь, обеспечивает возможность обнаружения неисправностей на ранних стадиях их развития. Она базируется на анализе различных параметров, характеризующих механические, теплофизические, электрические свойства диагностируемого объекта. Современные

методы диагностики сложных систем предполагают использование датчиков, алгоритмов обработки сигналов и методов машинного обучения для точного выявления аномалий и прогнозирования возможных отказов [2].

Таким образом, взамен реактивному и планово-предупредительному видам обслуживания в некоторых современных видах оборудования (например, в силовых установках производственных линий, автомобильного, авиационного видов транспорта, систем теплоэнергоснабжения и т. д.) отдается предпочтение предсказательному обслуживанию, которое позволяет прогнозировать появление неисправностей до их возникновения.

Особенно важно применение предсказательного обслуживания в контексте электропривода. Электродвигатели и механические преобразователи, входящие в состав электропривода, занимают центральное место в функционировании различных типов промышленного оборудования. Их выход из строя может привести к значительным производственным потерям и дорогостоящим ремонтам. В то время как реактивные и планово-предупредительные виды обслуживания могут быть неэффективными и дорогостоящими, предсказательное обслуживание позволяет прогнозировать потребности в обслуживании

живании и выявлять потенциальные проблемы до их возникновения.

Целью работы является систематизация существующих методов, применяемых на различных этапах построения системы предсказательного обслуживания в электроприводе.

В работе рассмотрена современная структура систем предсказательного обслуживания, включающая в себя такие этапы, как сбор данных, обработка данных, выделение признаков, диагностика и прогнозирование. Представлен обзор состоявшихся методов диагностики состояния электродвигателей (основанных на анализе вибраций, электрических сигналов, температуры). Кроме того, в работе обсуждаются методы машинного обучения, нашедшие свое применение в выделении признаков, классификации неисправностей, прогнозировании и, в целом, в предсказательном обслуживании электропривода.

### Предсказательное обслуживание электропривода

Техническое обслуживание электроприводов играет ключевую роль в обеспечении их эффективной работы и долговечности. Электродвигатели являются одними из наиболее важных элементов в промышленном оборудовании, обеспечивая привод механизмов и устройств. Предсказательное обслуживание путем анализа данных о состоянии электродвигателя, выявления потенциальных проблем и прогнозирования возможных отказов позволяет принимать меры по предотвращению неполадок до их возникновения.



Рис. 1. Этапы построения систем предсказательного обслуживания

Fig. 1. Stages of predictive maintenance systems

### 1. Сбор данных

Современная структура построения систем предсказательного обслуживания состоит из следующих ключевых этапов: сбор данных, преобразование данных, диагностика, прогнозирование, принятие решений, отображение данных в виде графического интерфейса пользователя (рис. 1) [3].

Данный этап является начальным этапом системы предсказательного обслуживания и описывается как процесс сбора и хранения данных, получаемых от датчиков или журналов технического обслуживания [4]. Журналы технического обслуживания содержат информацию о выполненных работах по техническому обслуживанию, включая ремонт, замену компонентов, а также зафиксированные отказы оборудования. Данные, получаемые от датчиков, – это измерения физических параметров системы (напряжение, ток, сопротивление, частота вращения, температура, виброускорение и т. д.).

### 2. Преобразование данных

Этап преобразования данных в предсказательном обслуживании играет ключевую роль. Необходимость обработки собранных данных в целом обусловлена повышением точности моделей машинного обучения и/или статистического анализа [5]. Преобразование данных включает в себя очистку данных и анализ данных.

Под очисткой данных подразумевается нахождение и удаление случайных ошибок в собранных данных, нормализация и заполнение пропусков в данных при их наличии. Необходимость выполнения этих шагов зависит от типа выбранной модели предсказательного обслуживания [6]. Например, для искусственных нейронных сетей требуется нормализация данных для приведения значений к единому масштабу, а для моделей, чувствительных к выбросам, может потребоваться удаление ошибок и шумов. Различные методы (статистические, регрессионные и т. д.) применяются в зависимости от специфики данных и выбранного подхода к анализу [7].

Анализ данных, который является второй частью предварительной обработки данных, включает в себя извлечение признаков, их оценку и отбор. Очищенные временные ряды данных должны пройти процедуру извлечения признаков, которые отражают прогрессирующие сбои в системе. Методы выделения признаков подразделяются на основанные на временной области, на частотной области и комбинированные (частотно-временная область) (табл. 1).

Таблица 1. Статистические методы выделения признаков в соответствии с областью и типом данных

Table 1. Statistical feature extraction techniques according to the domain and data type

| Область                    | Алгоритмы   | Тип данных   |
|----------------------------|---|--|
| Временная область          | Среднее квадратическое (RMS);<br>Крутизна распределения (Kurtosis);<br>Пик фактор (P2P);<br>Коэффициент асимметрии (Skewness) | Момент,<br>ток,<br>напряжение,<br>температура            |
| Частотная область          | Остаточный анализ (NA, NA4*);<br>Спектральная крутизна распределения;<br>Анализ среды функционирования (NB4)                  | Вибрация,<br>ток,<br>напряжение, акустические<br>сигналы |
| Частотно-временная область | Оконное преобразование<br>Фурье (STFT);<br>Преобразование Гильберта —<br>Хуанга (ННТ)   | Вибрация,<br>ток,<br>напряжение, акустические<br>сигналы |

Существуют различные методы, используемые для количественной оценки качества признака (т. е. тренда к ухудшению), такие как монотонность, прогнозируемость и др. [9]. Лучшие признаки, которые имеют явный тренд к ухудшению, отбираются для их использования в диагностике и прогнозировании.

### 3. Диагностика

Диагностика неисправностей – это процесс обнаружения неисправностей и оценка скорости их развития на основе информации о техническом состоянии машины [10]. Результаты диагностики могут быть использованы для принятия как реактивных, так и упреждающих решений о техническом обслуживании. В контексте диагностики электропривода устоялись методы, описанные в разделе 2, которые также включают в себя анализ данных в частотной и/или временной областях. Эти методы можно классифицировать по типу собираемых сигналов, таких как ток, вибрация, температура и др.

### 4. Прогнозирование

Прогнозирование можно разделить на две категории. Первая прогнозирует возможные виды отказов, основываясь на незначительных изменениях в измеряемых данных машины. Вторая категория оценивает остаточный полезный ресурс (RUL).

В этом случае оценивается состояние объекта, который со временем изнашивается. Таким образом, можно предсказать точку выхода из строя, принимая во внимание конкретный режим эксплуатации.

В последнее время, в публикациях отмечается сильная тенденция к созданию моделей предсказательного обслуживания, основанных на машинном обучении [11–13], что подробно рассмотрено в разделе 3.

### Диагностика состояния электропривода

Методы диагностики постоянно совершенствуются на протяжении нескольких десятилетий благодаря прогрессу в области сенсорных технологий, цифровой обработки сигналов и анализа данных. В современных системах предсказательного обслуживания технического оборудования широко используются следующие методы диагностики [14]:

- методы, основанные на анализе вибраций оборудования (Vibration Signature Analysis);
- методы, основанные на анализе электрических сигналов машины (Motor Current Signature Analysis);
- методы, основанные на измерении температуры в локальных зонах машины.

#### 1. Методы, основанные на анализе вибраций

Суть методов вибродиагностики заключается в анализе вибрационных параметров в различных точках электродвигателя. Контроль вибрационных параметров производят в нескольких точках. Регистрации подлежат вибрационные параметры в вертикальном, горизонтальном и осевом направлениях. В качестве первичных преобразователей используются как контактные датчики (обычно пьезоакселерометры), так и бесконтактные (оптические датчики перемещения). Большое распространение получили методы спектрального анализа, в которых в качестве диагностических параметров используют значения амплитуды отдельных гармонических составляющих вибрационного сигнала [15]. Вибродиагностика позволяет определить механические дефекты, такие как дисбаланс ротора и неисправности подшипников, а также некоторые дефекты статора (межвитковое замыкание обмотки, однофазность, несимметрия напряжений) [16, 17]. К недостаткам данных методов

можно отнести необходимость непосредственного доступа к диагностируемому агрегату для установки датчиков.

## 2. Методы, основанные на анализе электрических параметров

Анализ сигналов тока (Motor Current Signature Analysis MCSA) – это неинвазивный метод диагностики неисправностей электропривода. Этот метод основан на анализе токовых сигналов электропривода в частотной области (спектральный анализ, вейвлет-преобразование).

MCSA позволяет диагностировать следующие типы неисправностей: повреждение изоляции обмоток статора, поломка стержня ротора [18], эксцентриситет воздушного зазора ротора [19], дисбаланс ротора [20], неисправности подшипников [21].

Недостатком MCSA является низкая эффективность при анализе зашумленных сигналов, когда гармоники неисправностей накладываются на гармоники, вызванные внешними источниками шума (например, инвертор или питающее напряжение) [22].

Для устранения недостатков MCSA были разработаны подвиды, такие как Motor Squared Current Signature Analysis (MSCSA), Park Vector Approach (PVA), Instantaneous Power Signature Analysis (IPSA), Instantaneous Active Power Signature Analysis (IAPSA) и Instantaneous Reactive Power Analysis (IRPSA).

Метод MSCSA основывается на спектральном анализе токового сигнала, предварительно возведенного в квадрат. По данным автора [23], этот метод обеспечивает более высокую диагностическую точность по сравнению с MCSA.

Метод PVA основан на преобразовании трехфазной системы координат, привязанной к статору, во вращающуюся, ориентированную по вектору потокосцепления ротора (в случае асинхронного двигателя), и анализе получившегося вектора тока статора (вектора Парка) [24]:

$$i_p = |i_d + ji_q|; \quad (1)$$

$$i_d = \sqrt{\frac{2}{3}}i_a - \sqrt{\frac{1}{6}}i_b - \sqrt{\frac{1}{6}}i_c; \quad (2)$$

$$i_q = \sqrt{\frac{1}{2}}i_b - \sqrt{\frac{1}{2}}i_c, \quad (3)$$

где  $i_p$  – модуль вектора тока Парка;  $i_d$ ,  $i_q$  – составляющие вектора тока во вращающейся системе координат;  $i_a$ ,  $i_b$ ,  $i_c$  – составляющие вектора тока в неподвижной трехфазной системе координат.

Ключевой особенностью метода является анализ данных как во временной области, так и в частотной (Extended Park's Vector Approach EPVA) (рис. 2).

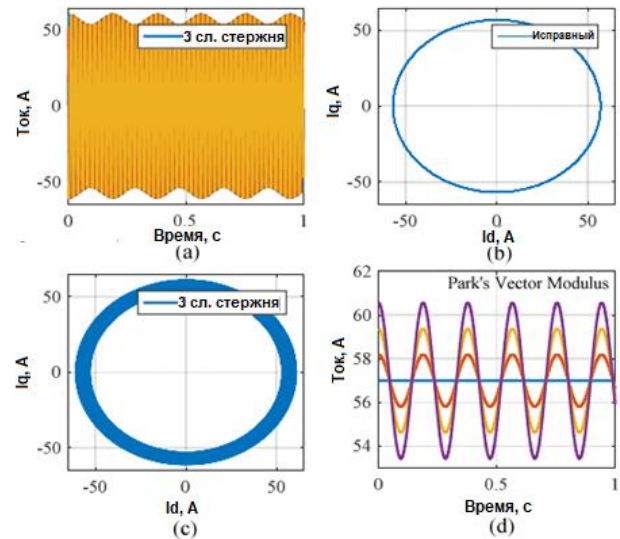


Рис. 2. Метод EPVA: *a* – фазные токи двигателя при повреждении 3 стержней ротора асинхронного двигателя, *b* – вектор тока Парка при не поврежденном состоянии ротора, *c* – вектор тока Парка при повреждении 3 стержней, *d* – модуль вектора тока Парка при неповрежденном роторе (голубой), повреждении 1-го стержня (красный), 2 (желтый) и 3 (фиолетовый) стержней [25]

Fig. 2.(a) Motor current with three broken bars, (b) Park's vector of the healthy motor, (c) Park's vector of the faulty motor with three broken bars, (d) Park's vector modulus of healthy (blue), 1 (red), 2 (yellow) and 3 (purple) broken rotor bars motor

Анализ во временной области позволяет выявлять неисправности электропривода при малейших отклонениях значений, в то время как анализ модуля вектора Парка в частотной области применяется для идентификации неисправностей [26–28].

Подход IPSA базируется на спектральном анализе мгновенных значений мощности электропривода. Используются различные разновидности: мгновенная полная (IPSA [29]), активная (IAPSA [30]) и реактивная мощности (IRPSA [31]). Ввиду того, что характеристические компоненты мощности обычно имеют большую амплитуду и встречаются в более узком диапазоне частот по сравнению с характеристическими компонентами тока, IPSA может быть более эффективным в случаях, когда сигнал зашумлен [32]. Недостатком же является необходимость в дополнительных датчиках для измерения фазных напряжений.

### **3. Методы, основанные на анализе температуры**

Тепловой контроль электродвигателя осуществляется путем измерения температуры в локальных зонах двигателя. Например, в случае межвиткового замыкания в статоре зона вокруг этого замыкания будет стремительно нагреваться. Однако стоит заметить, что для определения неисправности может потребоваться значительное время, за которое может произойти отказ электропривода. В связи с этим тепловой анализ имеет ограниченный потенциал [33]. Вместо этого тепловой контроль используется как дополнение к другим методам диагностики. Например, в работе [34] измерение температуры статора было применено вместе с MCSA для прогнозирования остаточного полезного ресурса бесколлекторного двигателя постоянного тока.

#### **Методы машинного обучения в предсказательном обслуживании электропривода**

Существуют две основные категории методов предсказательного обслуживания для электродвигателей: методы, основанные на обработке накопленных данных, и модельно-ориентированные методы, которые основаны на принципах работы обслуживаемого оборудования [35].

В модельно-ориентированных методах процесс деградации описывается математической моделью, основанной на физической системе. При этом значения параметров математической модели определяются или уточняются при помощи данных мониторинга [36]. Наиболее часто используемыми модельно-ориентированными методами являются закон Пэриса [37], фильтр Калмана [38], фильтр частиц [39] и т. д. Данные подходы отличаются точностью ввиду их привязки к математической модели системы и имеют долгосрочный горизонт прогнозирования, но требуют наличия большой базы экспертных знаний. Построение моделей на основе реальных физических систем является очень сложной задачей из-за необходимости в регулярной параметрической оптимизации моделей и стохастического характера деградации компонентов. Кроме того, создание и настройка таких моделей для сложных систем сопряжены с высокими затратами и привлечением экспертов, при этом учесть все параметры, изменения которых могут свидетельствовать о деградации системы (компонента), оказывается крайне затруднительно. Для преодоления данных недостатков были предложены и в настоящее время активно развиваются методы, основанные на использовании данных [40].

Методы, основанные на данных, позволяют определять и прогнозировать степень деградации оборудования на основе измеряемых параметров объекта, используя статистические методы, а также методы машинного обучения. Преимущество таких моделей заключается в их независимости от физической структуры исследуемого объекта, однако требуют больших вычислительных мощностей, чем подходы, основанные на моделях [41]. Точность таких подходов в значительной степени зависит от объема имеющихся данных.

В настоящее время в публикациях существует сильная тенденция к использованию методов машинного обучения в построении моделей предсказательного обслуживания электропривода. В ходе анализа литературных источников были выделены следующие часто встречаемые техники машинного обучения:

- методы глубокого обучения;
- методы классификации и регрессии.

#### **1. Методы глубокого обучения**

Глубокое обучение – это подмножество машинного обучения, использующее многослойные нейронные сети для анализа сложных данных. Применимость глубокого обучения в построении моделей предсказательного обслуживания электропривода обусловлена тем, что такие системы демонстрируют нелинейное поведение из-за взаимодействия множества факторов. Нейронные сети обладают рядом свойств, которые делают их эффективными для анализа таких систем, как обработка больших объемов многомерных данных, распознавание аномалий в данных, устойчивость к шуму, адаптивность к изменениям в системе [42]. Одним из основных недостатков нейронных сетей является то, что структура сети не может быть определена заранее. Топология сети, гиперпараметры и отсутствие интерпретируемости могут значительно влиять на качество модели и ее точность [43].

Рекуррентные нейронные сети (RNN) являются наиболее популярным методом глубокого обучения для оценки остаточного полезного ресурса (RUL) машин. Это связано с их высокой эффективностью в прогнозировании временных рядов, что подтверждается многочисленными исследованиями и успешными примерами применения в данной области. Особенно выделяются сети с долгой краткосрочной памятью (LSTM), которые способны лучше справляться с проблемой затухающего градиента и эффективно идентифицировать долгосрочные зависимости в данных [44–46].

Также имеются примеры успешного применения сверточных нейронных сетей в распознавании отказов электропривода на ранней стадии. Авторы [47] предложили систему, позволяющую обнаруживать электрические и механические неисправности асинхронного двигателя, используя сигналы тока и вибрации. Для объединения задачи классификации и извлечения признаков была использована 1-DCNN сеть.

Наконец, существуют работы, в которых автоэнкодеры используются в качестве вспомогательного инструмента при разработке моделей предсказательного обслуживания электропривода. В работе [48] представлен многоуровневый стековый автоэнкодер подавления шума

(Stacked multilevel-denoising autoencoder), который применяется для фильтрации данных от шума. В другой работе [49] глубокий автоэнкодер (Deep autoencoder) используется для выделения признаков, а метод опорных векторов (SVM) – для прогнозирования.

## 2. Методы классификации и регрессии

Среди класса методов классификации и регрессии, использующихся в предсказательном обслуживании электропривода, следует выделить такие методы, как метод случайного леса (RF), метод опорных векторов (SVM), логистическая регрессия (LR), наивный байесовский классификатор (NBC), метод k-ближайших соседей (k-NN) (табл. 2).

Таблица 2. Сравнение методов классификации и регрессии

Table 2. Comparison of classification and regression methods

| Алгоритм | Ключевая особенность   | Преимущества   | Недостатки  | Ссылки  |
|----------|--|--|---|---------|
| RF       | Использование ансамбля решающих деревьев   | Декорреляция деревьев принятия решений, минимальная настройка                              | Интерпретируемость (отсутствие прозрачности модели)                           | [50,51] |
| SVM      | Нахождение гиперплоскости с максимальным отступом  | Эффективен в обработке многомерных данных  | Чувствительность к шуму, нетривиальная задача выбора ядра                     | [52]    |
| KNN      | Классификация или регрессия, основанные на расстоянии между объектами в пространстве признаков | Простота в реализации и интерпретации  | Чувствителен к выбросам, большое потребление памяти и низкая скорость работы  | [53]    |
| LR       | Прогнозирование вероятности того, что значение принадлежит к определенному классу              | Подходит для бинарной классификации, эффективен для классификации неизвестных типов данных | Не подходит для данных со сложными взаимосвязями и некоррелированными данными | [54]    |
| NBC      | Основан на применении теоремы Байеса   | Эффективен для многоклассовой классификации  | Если тестовых данных нет в обучающих данных, то их невозможно предсказать     | [55]    |

Результаты проведенного обзора показали, что выбор алгоритма машинного обучения для предсказательного обслуживания электропривода не может основываться на универсальных принципах. Также данное утверждение наглядно показывает работы по сравнительному анализу методов машинного обучения в контексте предсказательного обслуживания электропривода. В работе [56] представлено сравнение различных методов, включая k-NN, LR, NBC и SVM. Автор сделал вывод о том, что LR показала наилучшие результаты. Однако в работе [57], в которой сравнивались LR, RF, k-NN и SVM, алгоритм RF продемонстрировал наивысшие показатели, тогда как LR оказалась наименее эффективной. В работе

[58] автор получил результаты, которые показали, что RF, SVM и RNN имеют примерно одинаковую точность, в то время как k-nn показал наименьшую точность.

## Заключение

Предсказательное обслуживание электропривода представляет собой важный шаг в оптимизации работы и увеличении сроков службы оборудования. В работе были рассмотрены ключевые этапы построения системы предсказательного обслуживания, которые включают сбор данных, преобразование данных, диагностику, прогнозирование, принятие решений, отображение данных. Анализ методов диагностики выявил наиболее эффективные и широко применяемые методы:

основанные на вибрационных и электрических сигналах. Преимуществами данных методов являются: 1) повышенная чувствительность, позволяющая выявлять неисправности на ранней стадии (в отличие от методов температурного, акустического анализа); 2) неинвазивность, что позволяет проводить диагностику без прерывания рабочего цикла оборудования; 3) универсальность, поскольку данные методы подходят для диагностики практически всех типов электроприводов (в отличие, например, от анализа магнитного потока, присущего преимущественно только асинхронным двигателям); 4) широкий спектр диагностируемых неисправностей. Результаты проведенного обзора методов машинного обучения показывают, что эффективность алгоритмов зависит от специфики наборов данных и условий их применения. Стоит отметить, такие методы, как случайный лес и нейронные сети долгой краткосрочной памяти, часто встречаются в исследованиях, проведенных на производственных объектах, а не только на лабораторных стендах, и демонстрируют высокую точность в прогнозировании неисправностей. Также заслуживают внимания методы SVM и k-NN, которые показывают улучшение точности прогнозирования при использовании нескольких методов диагностики одновременно. Комбинирование различных источников данных, таких как вибрационные и электрические сигналы, позволяет этим алгоритмам более точно выявлять потенциальные неисправности и повышать эффективность предсказательного обслуживания. В связи с этим перед выбором метода для системы предсказательного обслуживания крайне важно провести всестороннее исследование и сравнительный анализ различных подходов, учитывающих особенности задач и характеристики данных, связанных с электроприводами. Таким образом, решение о выборе оптимального алгоритма должно приниматься на основе конкретных условий и требований, а не на основании универсальных рекомендаций.

#### Библиографические ссылки

1. Gu C., He Y., Han X., Chen Z. Product quality oriented predictive maintenance strategy for manufacturing systems // 2017 Prognostics and System Health Management Conference (PHM-Harbin). 2017. pp. 1-7. DOI: 10.1109/PHM.2017.8079213.
2. Fossier S., Robic P. Maintenance of complex systems - From preventive to predictive // 2017 12th International Conference on Live Maintenance (ICOLIM). 2017. pp. 1-6. DOI: 10.1109/ICOLIM.2017.7964123.
3. ГОСТ Р ИСО 13374-1–2011. Контроль состояния и диагностика машин. Обработка, передача и представление данных : Национальный стандарт Российской Федерации : дата введения 2012-12-01 / Федеральное агентство по техническому регулированию. Изд. официальное. М. : Стандартинформ, 2018. 20 с.
4. ГОСТ Р ИСО 13380–2002 Диагностикарование машин по рабочим характеристикам. Общие положения : Межгосударственный стандарт : дата введения 2005-08-11 / Федеральное агентство по техническому регулированию. – Изд. официальное. М. : Стандартинформ, 2005. 23 с.
5. Romansini M., de Aguirre P., Severo L., Girardi A. A Review on Vibration Monitoring Techniques for Predictive Maintenance of Rotating Machinery // Eng – Advances in Engineering. 2023. Vol. 4(3). pp. 1797-1817. DOI: 10.3390/eng4030102.
6. Haneen Arafat Abu Alfeilat, Ahmad B.A. Hassanat, Omar Lasassmehet al. Effects of Distance Measure Choice on K-Nearest Neighbor Classifier Performance: A Review // Big Data. 2019. Vol. 7(4). Pp. 221-248. DOI: 10.1089/big.2018.0175.
7. Cernuda C. On the relevance of preprocessing in predictive maintenance for dynamic systems // Predictive Maintenance in Dynamic Systems. 2019. pp. 53–93. DOI: 10.1007/978-3-030-05645-2\_3.
8. Atamuradov V., Medjaher K., Camci F. et al. Machine Health Indicator Construction Framework for Failure Diagnostics and Prognostics // Journal of Signal Processing Systems. 2020. Vol. 92 (8). DOI: 10.1007/s11265-019-01491-4.
9. Atamuradov V., Camci F. Segmentation based feature evaluation and fusion for prognostics feature selection based on segment evaluation // The International Journal of Prognostics and Health Management. 2017. Vol. 8(2). Pp. 1–14. DOI: 10.36001/ijphm.2017.v8i2.2643.
10. ГОСТ Р ИСО 13372–2013 Контроль состояния и диагностика машин. Термины и определения : Национальный стандарт Российской Федерации : дата введения 2013-11-22 / Федеральное агентство по техническому регулированию. Изд. официальное. М. : Стандартинформ, 2019. 20 с.
11. Kumar S., Mukherjee D., Kumar. P. et al. A Comprehensive Review of Condition Based Prognostic Maintenance (CBPM) for Induction Motor // IEEE Access. 2019. Vol. 7, pp. 90690-90704. DOI: 10.1109/ACCESS.2019.2926527.
12. Panov S., Nikolov A., Panova S. Review of standards and systems for predictive maintenance // Science, Engineering and Education. 2021. Vol. 6 (1). DOI: 10.59957/see.v6.i1.2020.1
13. Bhandari M., Silwal B. Development of Machine Learning Model Applied to Industrial Motors for Predictive Maintenance // 2022 International Interdisciplinary Humanitarian Conference for Sustainability (IIHC). 2022. Pp. 1632-1635. DOI: 10.1109/IIHC55949.2022.10060358.
14. Aniket M., Babasaheb P. A Review: Condition Based Techniques and Predictive Maintenance for Motor. // 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS). 2021. Pp. 807-813. DOI: 10.1109/ICAIS50930.2021.9395903.
15. Nouredine B., Remus P., Raphael R., Salim S. Rolling Bearing Failure Detection in Induction Motors using Stator Current, Vibration and Stray Flux Analysis Techniques // IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society. 2020. Pp.

1088-1095. DOI: 10.1109/IECON43393.2020.9254401.

16. Bhaumik D., Sadda A., Puneekar G. Vibration Signal Analysis of Induction Motor Bearing Faults: Some Aspects // 2023 International Conference on Smart Systems for applications in Electrical Sciences (ICSSES). 2023. Pp. 1-4. DOI: 10.1109/ICSSES58299.2023.10200270.

17. Dehina W., Boumehraz M., Kratz F., Fantini J. Diagnosis and Comparison between Stator Current Analysis and Vibration Analysis of Static Eccentricity Faults in The Induction Motor. // 4th International Conference on Power Electronics and their Applications (ICPEA). 2019. pp. 1-4, DOI: 10.1109/ICPEA1.2019.8911193.

18. Pires V., Martins F., Pires A., Rodrigues L. Induction motor broken bar fault detection based on MCSA, MSCSA and PCA: A comparative study // IEEE 2016 10th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG). 2016. Pp. 298-303. DOI:10.1109/CPE.2016.7544203.

19. Rafiq M., Faizan Shaikh M., Park Y., Lee S. Reliable Airgap Search Coil Based Detection of Induction Motor Rotor Faults Under False Negative Motor Current Signature Analysis Indications // IEEE Transactions on Industrial Informatics. 2022. Vol. 18 (5). Pp. 3276-3285. DOI: 10.1109/TII.2020.3042195.

20. Ishkova I., Vitek O. Diagnosis of eccentricity and broken rotor bar related faults of induction motor by means of motor current signature analysis // 2015 16th International Scientific Conference on Electric Power Engineering (EPE). 2015. p. 682-686. DOI: 10.1109/EPE.2015.7161130.

21. Yeolekar S., Mulay G., Helonde J. Outer race bearing fault identification of induction motor based on stator current signature by wavelet transform // 2017 2nd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT). 2017. pp. 2011-2015. DOI: 10.1109/RTEICT.2017.8256951.

22. Becker V., Schwamm T., Urschel S., Antonino-Daviu J. Fault Detection of Circulation Pumps on the Basis of Motor Current Evaluation // IEEE Transactions on Industry Applications. 2021. Vol. 57 (5). Pp. 4617-4624. DOI: 10.1109/TIA.2021.3085697.

23. Pires V., Foito D., Martins J., Pires A. Detection of stator winding fault in induction motors using a motor square current signature analysis (MSCSA) // 2015 IEEE 5th International Conference on Power Engineering, Energy and Electrical Drives (POWERENG). 2015. Pp. 507-512. DOI: 10.1109/PowerEng.2015.7266369.

24. Kandukuri S., Huynh V., Robbersmyr K. Diagnostics of stator winding failures in wind turbine pitch motors using Vold-Kalman filter // IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society. 2019. Pp. 5992-5997. DOI: 10.1109/IECON.2019.8926983.

25. Asad B., Vaimann T., Belahcen A., Kallaste A. Broken Rotor Bar Fault Diagnostic of Inverter Fed Induction Motor Using FFT, Hilbert and Park's Vector Approach // 2018 XIII International Conference on Electrical Machines (ICEM). 2018. Pp. 2352-2358. DOI: 10.1109/ICELMACH.2018.8506957.

26. Messaoudi M., Flah A., Alotaibi A. et al. Diagnosis and fault detection of rotor bars in squirrelcage induction motors using combined park's vector and extended park's vector approaches // Electronics. 2022. Vol. 11 (3). DOI:

10.3390/electronics11030380.

27. Silva J., Cardoso A. Bearing failures diagnosis in three-phase induction motors by extended Park's vector approach // 31st Annual Conference of IEEE Industrial Electronics Society. 2005. DOI: 10.1109/IECON.2005.1569315.

28. Guefack F., Kiselev A., Kuznetsov A. Improved Detection of Inter-turn Short Circuit Faults in PMSM Drives using Principal Component Analysis // 2018 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM). 2018. pp. 154-159. DOI: 10.1109/SPEEDAM.2018.8445403.

29. Niu G., Dong X., Chen Y. Motor Fault Diagnostics Based on Current Signatures: A Review // IEEE Transactions on Instrumentation and Measurement. 2023. Vol. 72. Pp. 1-19. DOI: 10.1109/TIM.2023.3285999.

30. Furse C., Kafal M., Razzaghi R., Shin Y. Fault Diagnosis for Electrical Systems and Power Networks: A Review // IEEE Sensors Journal. 2021. Vol. 21 (2). Pp. 888-906. DOI: 10.1109/JSEN.2020.2987321.

31. Bianchini C., Torreggiani A., Davoli M. et al. Stator fault diagnosis by reactive power in dual three-phase reluctance motors // 2019 IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED). 2019. Pp. 251-256. DOI: 10.1109/SDEMPED.2019.8864909.

32. Drif M., Cardoso A. Stator Fault Diagnostics in Squirrel Cage Three-Phase Induction Motor Drives Using the Instantaneous Active and Reactive Power Signature Analyses // IEEE Transactions on Industrial Informatics. 2014. Vol. 10 (2). Pp. 1348-1360. DOI: 10.1109/TII.2014.2307013.

33. Maciejewski N., Trembl A., Flauzino R. A Systematic Review of Fault Detection and Diagnosis Methods for Induction Motors // 2020 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE). 2020. Pp. 86-90. DOI: 10.1109/FORTEI-ICEE50915.2020.9249890.

34. Shifat T., Jang-Wook H. Remaining Useful Life Estimation of BLDC Motor Considering Voltage Degradation and Attention-Based Neural Network // IEEE Access. 2020. Vol. 8. Pp. 168414-168428. DOI: 10.1109/ACCESS.2020.3023335.

35. Atamuradov V., Medjaher K., Dersin P. et al. Prognostics and Health Management for Maintenance Practitioners-Review, Implementation and Tools Evaluation // International Journal of Prognostics and Health Management. 2018. Vol. 8. DOI: 10.36001/ijphm.2017.v8i3.2667.

36. Huang W., Huang Y., Luo L., Zhou L. A Mixed Logical Dynamic Model-Based Open-Circuit Fault Diagnosis Method for Five-Phase PMSM Drives // 2023 26th International Conference on Electrical Machines and Systems (ICEMS). 2023, pp. 3641-3646. DOI: 10.1109/ICEMS59686.2023.10344412.

37. Behzad M., Arghan H., Bastami A., Zuo M. Prognostics of rolling element bearings with the combination of paris law and reliability method // 2017 Prognostics and System Health Management Conference (PHM-Harbin). 2017. pp. 1-6. DOI: 10.1109/PHM.2017.8079187.

38. Moon C., Han J., Kwon Y. Square-root unscented Kalman filter for state estimation of permanent magnet synchronous motor // 2016 55th Annual Conference of the So-

ciety of Instrument and Control Engineers of Japan (SICE). 2016. Pp. 460-464. DOI: 10.1109/SICE.2016.7749203.

39. Zhang Y., Guo R. Fault Diagnosis for Rolling Bearings Based on the Quadrature Particle Filter // 2020 Chinese Control And Decision Conference (CCDC). 2020. Pp. 2148-2155. DOI: 10.1109/CCDC49329.2020.9164797.

40. Liu L., Guo Y., Lei G., Zhu J. Review of Data-Driven Artificial Intelligence Applications in Electric Machines and Drive Systems // 2023 IEEE International Future Energy Electronics Conference (IFEEEC). 2023. Pp. 93-97. DOI: 10.1109/IFEEEC58486.2023.10458448.

41. Briza A., Piedad E., Peramo E. Simpler Machine Learning Methods Outperform Deep Learning in Motor Fault Detection // 2024 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC). 2024. Pp. 675-680. DOI: 10.1109/ICAIIIC60209.2024.10463445.

42. Su Y., Gao L., Lu Y. et al. Intelligent Diagnosis Research of Motor Drive Systems Based on Neural Networks // 2024 3rd International Conference on Energy and Electrical Power Systems (ICEEPS). 2024. Pp. 1101-1105. DOI: 10.1109/ICEEPS62542.2024.10693252.

43. Sameh M., Tarek A. Yassine K. Bearing and Rotor Faults detection and diagnosis of Induction Motors using Statistical Neural Networks // 2020 20th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA). 2020. Pp. 77-81. DOI: 10.1109/STA50679.2020.9329334.

44. Khaniki M., Mirzaebonekhater M., Manthouri M. Enhancing Fault Detection in Induction Motors using LSTM-Attention Neural Networks // 2023 9th International Conference on Control, Instrumentation and Automation (ICCIA). 2023. Pp. 1-5. DOI: 10.1109/ICCIA61416.2023.10506369.

45. Samanta S., Bera J., Biswas A. Induction Motor Interturn Short Circuit Fault Classification by Extracting Auto Features Using LSTM Neural Network // 2024 IEEE 3rd International Conference on Control, Instrumentation, Energy & Communication (CIEC). 2024. Pp. 180-185. DOI: 10.1109/CIEC59440.2024.10468522.

46. Husari F., Seshadrinath J. Sensitive Inter-Turn Fault Identification in Induction Motors Using Deep Learning Based Methods // 2020 IEEE International Conference on Power Electronics, Smart Grid and Renewable Energy (PE-SGRE2020). 2020. Pp. 1-6. DOI: 10.1109/PESGRE45664.2020.9070334.

47. Han J., Choi D., Park S., Hong S. Diagnosis of motor aging through CNN model using signal correlation // 2020 20th International Conference on Control, Automation and Systems (ICCAS). 2020. Pp. 571-575. DOI: 10.23919/ICCAS0221.2020.9268420.

48. Jiang G., He H., Xie P. Tang Y., Stacked Multilevel-Denoising Autoencoders: A New Representation Learning Approach for Wind Turbine Gearbox Fault Diagnosis // IEEE Transactions on Instrumentation and Measurement. 2017. Vol. 66 (9). Pp. 2391-2402. DOI: 10.1109/TIM.2017.2698738.

49. Kandukuri S., Van Khang H., Robbsersmyr K. Multi-Component Fault Detection in Wind Turbine Pitch Systems Using Extended Park's Vector and Deep Autoencoder Feature Learning // 2018 21st International Conference on Electrical Machines and Systems (ICEMS). 2018. Pp. 1002-1007.

DOI:

10.23919/

ICEMS.2018.8549293.

50. Yaqub R., Ali H., Bin M. Electrical Motor Fault Detection System using AI's Random Forest Classifier Technique // 2023 IEEE International Conference on Advanced Systems and Emergent Technologies (IC\_ASET). 2023. Pp. 1-5. DOI: 10.1109/IC\_ASET58101.2023.10150924.

51. Amihai I., Gitzel R., Kotriwala A. et al. An industrial case study using vibration data and machine learning to predict asset health. // 2018 IEEE 20th Conference on Business Informatics (CBI). 2018. Vol. 1, pp. 178-185.

52. Kammoun J., Lajnef H., Ghariani M., Hamed B., Fakhfakh M. Diagnostic of Induction Motor Eccentricity Defaults in Electrical Vehicles using SVM // 2024 4th International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET). 2024. Pp. 01-05. DOI: 10.1109/IRASET60544.2024.10549645.

53. Silva R., Giesbrecht M. Detection of Broken Rotor Bars in Induction Motors through the k-NN Algorithm Combined with a Deterministic-Stochastic Subspace Method for System Identification // IECON 2021 – 47th Annual Conference of the IEEE Industrial Electronics Society. 2021. Pp. 1-6. DOI: 10.1109/IECON48115.2021.9589128.

54. Zainol A. Burhani N. Detecting Most Influential Parameters in High Voltage Induction Motor Failure using Logistic Regression Analysis // 2022 2nd International Seminar on Machine Learning, Optimization, and Data Science (IS-MODE). 2022. Pp. 82-86. DOI: 10.1109/ISMODE56940.2022.10180980.

55. Floresca F., Kyle Tobias C., Ostia C. Naïve Bayes Classification Technique for Brushless DC Motor Fault Diagnosis with Discrete Wavelet Transform Feature Extraction // 2022 14th International Conference on Computer and Automation Engineering (ICCAE). 2022. Pp. 140-144. DOI: 10.1109/ICCAE55086.2022.9762447.

56. Bundasak S., Wittayasirikul P. Predictive maintenance using AI for Motor health prediction system // 2022 International Electrical Engineering Congress (IEEECON). 2022. Pp. 1-4. DOI: 10.1109/IEEECON53204.2022.9741620.

57. Limprasert N., Thimtheang T., Wattanakul K. et al. Predictive Maintenance Using Machine Learning // 2023 Research, Invention, and Innovation Congress: Innovative Electricals and Electronics (RI2C). 2023. pp. 235-240. DOI: 10.1109/RI2C60382.2023.10356007.

58. Singh S., Gill R., Kumar R. et al. A Comparative Analysis of Machine Learning Algorithms for Predictive Maintenance in Electrical Systems // 2024 4th International Conference on Innovative Practices in Technology and Management (ICIPTM). 2024. Pp. 1-6. DOI: 10.1109/ICIPTM59628.2024.10563826.

## References

1. Gu C., He Y., Han X., Chen Z. Product quality oriented predictive maintenance strategy for manufacturing systems // 2017 Prognostics and System Health Management Conference (PHM-Harbin). 2017. pp. 1-7. DOI: 10.1109/PHM.2017.8079213.

2. Fossier S., Robic P. Maintenance of complex systems - From preventive to predictive // 2017 12th International Con-

- ference on Live Maintenance (ICOLIM). 2017. pp. 1-6. DOI: 10.1109/ICOLIM.2017.7964123.
3. ISO(2011) Condition monitoring and diagnostics of machines — Data processing, communication and presentation (ISO Standart No.13374-1:2011).
4. ISO(2002) Condition monitoring and diagnostics of machines — General guidelines on using performance parameters (ISO Standart No.13380:2002).
5. Romanssini M., de Aguirre P., Severo L., Girardi A. A Review on Vibration Monitoring Techniques for Predictive Maintenance of Rotating Machinery // Eng – Advances in Engineering. 2023. Vol. 4(3). pp.1797-1817. DOI: 10.3390/eng4030102.
6. Haneen Arafat Abu Alfeilat, Ahmad B.A. Hassanat, Omar Lasassmehet al. Effects of Distance Measure Choice on K-Nearest Neighbor Classifier Performance: A Review // Big Data. 2019. Vol. 7(4). Pp. 221-248. DOI: 10.1089/big.2018.0175.
7. Cernuda C. On the relevance of preprocessing in predictive maintenance for dynamic systems // Predictive Maintenance in Dynamic Systems. 2019. pp. 53–93. DOI: 10.1007/978-3-030-05645-2\_3.
8. Atamuradov V., Medjaher K., Camci F. et al. Machine Health Indicator Construction Framework for Failure Diagnostics and Prognostics // Journal of Signal Processing Systems. 2020. Vol. 92 (8). DOI: 10.1007/s11265-019-01491-4.
9. Atamuradov V., Camci F. Segmentation based feature evaluation and fusion for prognostics feature selection based on segment evaluation // The International Journal of Prognostics and Health Management. 2017. Vol. 8(2). Pp. 1–14. DOI: 10.36001/ijphm.2017.v8i2.2643.
10. ISO(2013) Condition monitoring and diagnostics of machines - Vocabulary (ISOStandartNo.13372:2013).
11. Kumar S., Mukherjee D., Kumar. P. et al. A Comprehensive Review of Condition Based Prognostic Maintenance (CBPM) for Induction Motor // IEEE Access. 2019. Vol. 7, pp. 90690-90704. DOI: 10.1109/ACCESS.2019.2926527.
12. Panov S., Nikolov A., Panova S. Review of standarts and systems for predictive maintenance // Science, Engineering and Education. 2021. Vol. 6 (1). DOI: 10.59957/see.v6.i1.2020.1
13. Bhandari M., Silwal B. Development of Machine Learning Model Applied to Industrial Motors for Predictive Maintenance // 2022 International Interdisciplinary Humanitarian Conference for Sustainability (IIHC). 2022. Pp. 1632-1635. DOI: 10.1109/IIHC55949.2022.10060358.
14. Aniket M., Babasaheb P. A Review: Condition Based Techniques and Predictive Maintenance for Motor. // 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS).2021. Pp. 807-813. DOI:10.1109/ICAIS50930.2021.9395903.
15. Noureddine B., Remus P., Raphael R., Salim S. Rolling Bearing Failure Detection in Induction Motors using Stator Current, Vibration and Stray Flux Analysis Techniques // IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society. 2020. Pp. 1088-1095. DOI: 10.1109/IECON43393.2020.9254401.
16. Bhaumik D., Sadda A., Puneekar G. Vibration Signal Analysis of Induction Motor Bearing Faults: Some Aspects // 2023 International Conference on Smart Systems for applications in Electrical Sciences (ICSSES). 2023. Pp. 1-4. DOI: 10.1109/ICSSES58299.2023.10200270.
17. Dehina W., Boumehraz M., Kratz F., Fantini J. Diagnosis and Comparison between Stator Current Analysis and Vibration Analysis of Static Eccentricity Faults in The Induction Motor. // 4th International Conference on Power Electronics and their Applications (ICPEA). 2019. pp. 1-4, DOI: 10.1109/ICPEA1.2019.8911193.
18. Pires V., Martins F., Pires A., Rodrigues L. Induction motor broken bar fault detection based on MCSA, MSCSA and PCA: A comparative study // IEEE 2016 10th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG). 2016. Pp. 298–303. DOI:10.1109/CPE.2016.7544203.
19. Rafaq M., Faizan Shaikh M., Park Y., Lee S. Reliable Airgap Search Coil Based Detection of Induction Motor Rotor Faults Under False Negative Motor Current Signature Analysis Indications // IEEE Transactions on Industrial Informatics. 2022. Vol. 18 (5). Pp. 3276-3285. DOI: 10.1109/TII.2020.3042195.
20. Ishkova I., Vitek O. Diagnosis of eccentricity and broken rotor bar related faults of induction motor by means of motor current signature analysis // 2015 16th International Scientific Conference on Electric Power Engineering (EPE). 2015. p. 682-686. DOI: 10.1109/EPE.2015.7161130.
21. Yeolekar S., Mulay G., Helonde J. Outer race bearing fault identification of induction motor based on stator current signature by wavelet transform // 2017 2nd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT). 2017. pp. 2011-2015. DOI: 10.1109/RTEICT.2017.8256951.
22. Becker V., Schwamm T., Urschel S., Antonino-Daviu J. Fault Detection of Circulation Pumps on the Basis of Motor Current Evaluation // IEEE Transactions on Industry Applications. 2021. Vol. 57 (5). Pp. 4617-4624. DOI: 10.1109/TIA.2021.3085697.
23. Pires V., Foito D., Martins J., Pires A. Detection of stator winding fault in induction motors using a motor square current signature analysis (MSCSA) // 2015 IEEE 5th International Conference on Power Engineering, Energy and Electrical Drives (POWERENG). 2015. Pp. 507-512. DOI: 10.1109/PowerEng.2015.7266369.
24. Kandukuri S., Huynh V., Robbersmyr K. Diagnostics of stator winding failures in wind turbine pitch motors using Vold-Kalman filter // IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society. 2019. Pp. 5992-5997. DOI: 10.1109/IECON.2019.8926983.
25. Asad B., Vaimann T., Belahcen A., Kallaste A. Broken Rotor Bar Fault Diagnostic of Inverter Fed Induction Motor Using FFT, Hilbert and Park's Vector Approach // 2018 XIII International Conference on Electrical Machines (ICEM). 2018. Pp. 2352-2358. DOI: 10.1109/ICELMACH.2018.8506957.
26. Messaoudi M., Flah A., Alotaibi A. et al. Diagnosis and fault detection of rotor bars in squirrelcage induction motors using combined park's vector and extended park's vector approaches // Electronics. 2022. Vol. 11 (3). DOI: 10.3390/electronics11030380.
27. Silva J., Cardoso A. Bearing failures diagnosis in three-phase induction motors by extended Park's vector approach // 31st Annual Conference of IEEE Industrial Elec-

tronics Society. 2005. DOI: 10.1109/IECON.2005.1569315.

28. Guefack F., Kiselev A., Kuznetsov A. Improved Detection of Inter-turn Short Circuit Faults in PMSM Drives using Principal Component Analysis // 2018 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM). 2018. pp. 154-159. DOI: 10.1109/SPEEDAM.2018.8445403.

29. Niu G., Dong X., Chen Y. Motor Fault Diagnostics Based on Current Signatures: A Review // IEEE Transactions on Instrumentation and Measurement. 2023. Vol. 72. Pp. 1-19. DOI: 10.1109/TIM.2023.3285999.

30. Furse C., Kafal M., Razzaghi R., Shin Y. Fault Diagnosis for Electrical Systems and Power Networks: A Review // IEEE Sensors Journal. 2021. Vol. 21 (2). Pp. 888-906. DOI: 10.1109/JSEN.2020.2987321.

31. Bianchini C., Torreggiani A., Davoli M. et al. Stator fault diagnosis by reactive power in dual three-phase reluctance motors // 2019 IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED). 2019. Pp. 251-256. DOI: 10.1109/DEMPED.2019.8864909.

32. Drif M., Cardoso A. Stator Fault Diagnostics in Squirrel Cage Three-Phase Induction Motor Drives Using the Instantaneous Active and Reactive Power Signature Analyses // IEEE Transactions on Industrial Informatics. 2014. Vol. 10 (2). Pp. 1348-1360. DOI: 10.1109/TII.2014.2307013.

33. Maciejewski N., Trembl A., Flauzino R. A Systematic Review of Fault Detection and Diagnosis Methods for Induction Motors // 2020 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE). 2020. Pp. 86-90. DOI: 10.1109/FORTEI-ICEE50915.2020.9249890.

34. Shifat T., Jang-Wook H. Remaining Useful Life Estimation of BLDC Motor Considering Voltage Degradation and Attention-Based Neural Network // IEEE Access. 2020. Vol. 8. Pp. 168414-168428. DOI: 10.1109/ACCESS.2020.3023335.

35. Atamuradov V., Medjaher K., Dersin P. et al. Prognostics and Health Management for Maintenance Practitioners-Review, Implementation and Tools Evaluation // International Journal of Prognostics and Health Management. 2018. Vol. 8. DOI: 10.36001/ijphm.2017.v8i3.2667.

36. Huang W., Huang Y., Luo L., Zhou L. A Mixed Logical Dynamic Model-Based Open-Circuit Fault Diagnosis Method for Five-Phase PMSM Drives // 2023 26th International Conference on Electrical Machines and Systems (ICEMS). 2023. pp. 3641-3646. DOI: 10.1109/ICEMS59686.2023.10344412.

37. Behzad M., Arghan H., Bastami A., Zuo M. Prognostics of rolling element bearings with the combination of Paris law and reliability method // 2017 Prognostics and System Health Management Conference (PHM-Harbin). 2017. pp. 1-6. DOI: 10.1109/PHM.2017.8079187.

38. Moon C., Han J., Kwon Y. Square-root unscented Kalman filter for state estimation of permanent magnet synchronous motor // 2016 55th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE). 2016. Pp. 460-464. DOI: 10.1109/SICE.2016.7749203.

39. Zhang Y., Guo R. Fault Diagnosis for Rolling Bearings Based on the Quadrature Particle Filter // 2020 Chinese Control And Decision Conference (CCDC). 2020. Pp. 2148-2155. DOI: 10.1109/CCDC49329.2020.9164797.

40. Liu L., Guo Y., Lei G., Zhu J. Review of Data-Driven Artificial Intelligence Applications in Electric Machines and Drive Systems // 2023 IEEE International Future Energy Electronics Conference (IFEEC). 2023. Pp. 93-97. DOI: 10.1109/IFEEC58486.2023.10458448.

41. Briza A., Piedad E., Peramo E. Simpler Machine Learning Methods Outperform Deep Learning in Motor Fault Detection // 2024 International Conference on Artificial Intelligence in Information and Communication (ICAIC). 2024. Pp. 675-680. DOI: 10.1109/ICAIC60209.2024.10463445.

42. Su Y., Gao L., Lu Y. et al. Intelligent Diagnosis Research of Motor Drive Systems Based on Neural Networks // 2024 3rd International Conference on Energy and Electrical Power Systems (ICEEPS). 2024. Pp. 1101-1105. DOI: 10.1109/ICEEPS62542.2024.10693252.

43. Sameh M., Tarek A., Yassine K. Bearing and Rotor Faults detection and diagnosis of Induction Motors using Statistical Neural Networks // 2020 20th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA). 2020. Pp. 77-81. DOI: 10.1109/STA50679.2020.9329334.

44. Khaniki M., Mirzaeibonehkhater M., Manthouri M. Enhancing Fault Detection in Induction Motors using LSTM-Attention Neural Networks // 2023 9th International Conference on Control, Instrumentation and Automation (ICCIA). 2023. Pp. 1-5. DOI: 10.1109/ICCIA61416.2023.10506369.

45. Samanta S., Bera J., Biswas A. Induction Motor Inter-turn Short Circuit Fault Classification by Extracting Auto Features Using LSTM Neural Network // 2024 IEEE 3rd International Conference on Control, Instrumentation, Energy & Communication (CIEC). 2024. Pp. 180-185. DOI: 10.1109/CIEC59440.2024.10468522.

46. Husari F., Seshadrinath J. Sensitive Inter-Turn Fault Identification in Induction Motors Using Deep Learning Based Methods // 2020 IEEE International Conference on Power Electronics, Smart Grid and Renewable Energy (PESGRE2020). 2020. Pp. 1-6. DOI: 10.1109/PESGRE45664.2020.9070334.

47. Han J., Choi D., Park S., Hong S. Diagnosis of motor aging through CNN model using signal correlation // 2020 20th International Conference on Control, Automation and Systems (ICCAS). 2020. Pp. 571-575. DOI: 10.23919/ICCAS50221.2020.9268420.

48. Jiang G., He H., Xie P., Tang Y., Stacked Multilevel-Denoising Autoencoders: A New Representation Learning Approach for Wind Turbine Gearbox Fault Diagnosis // IEEE Transactions on Instrumentation and Measurement. 2017. Vol. 66 (9). Pp. 2391-2402. DOI: 10.1109/TIM.2017.2698738.

49. Kandukuri S., Van Khang H., Robbersmyr K. Multi-Component Fault Detection in Wind Turbine Pitch Systems Using Extended Park's Vector and Deep Autoencoder Feature Learning // 2018 21st International Conference on Electrical Machines and Systems (ICEMS). 2018. Pp. 1002-1007. DOI: 10.23919/ICEMS.2018.8549293.

50. Yaqub R., Ali H., Bin M. Electrical Motor Fault Detection System using AI's Random Forest Classifier Technique // 2023 IEEE International Conference on Advanced Systems and Emergent Technologies (IC\_ASET). 2023. Pp. 1-5. DOI: 10.1109/IC\_ASET58101.2023.10150924.

51. Amihai I., Gitzel R., Kotriwala A. et al. An industrial

case study using vibration data and machine learning to predict asset health. // 2018 IEEE 20th Conference on Business Informatics (CBI). 2018. Vol. 1, pp. 178-185.

52. Kammoun J., Lajnef H., Ghariani M., Hamed B., Fakhfakh M. Diagnostic of Induction Motor Eccentricity Defaults in Electrical Vehicles using SVM // 2024 4th International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET). 2024. Pp. 01-05. DOI: 10.1109/IRASET60544.2024.10549645.

53. Silva R., Giesbrecht M. Detection of Broken Rotor Bars in Induction Motors through the k-NN Algorithm Combined with a Deterministic-Stochastic Subspace Method for System Identification // IECON 2021 – 47th Annual Conference of the IEEE Industrial Electronics Society. 2021. Pp. 1-6. DOI: 10.1109/IECON48115.2021.9589128.

54. Zainol A. Burhani N. Detecting Most Influential Parameters in High Voltage Induction Motor Failure using Logistic Regression Analysis // 2022 2nd International Seminar on Machine Learning, Optimization, and Data Science (IS-MODE). 2022. Pp. 82-86. DOI: 10.1109/ISMODE56940.2022.10180980.

55. Floresca F., Kyle Tobias C., Ostia C. Naïve Bayes Classification Technique for Brushless DC Motor Fault Diagnosis with Discrete Wavelet Transform Feature Extraction // 2022 14th International Conference on Computer and Automation Engineering (ICCAE). 2022. Pp. 140-144. DOI: 10.1109/ICCAE55086.2022.9762447.

56. Bundasak S., Wittayasirikul P. Predictive maintenance using AI for Motor health prediction system // 2022 International Electrical Engineering Congress (iEECON). 2022. Pp. 1-4. DOI: 10.1109/iEECON53204.2022.9741620.

57. Limprasert N., Thimtheang T., Wattanakul K. et al. Predictive Maintenance Using Machine Learning // 2023 Research, Invention, and Innovation Congress: Innovative Electricals and Electronics (RI2C). 2023. pp. 235-240. DOI: 10.1109/RI2C60382.2023.10356007.

58. Singh S., Gill R., Kumar R. et al. A Comparative Analysis of Machine Learning Algorithms for Predictive Maintenance in Electrical Systems // 2024 4th International Conference on Innovative Practices in Technology and Management (ICIPTM). 2024. Pp. 1-6. DOI: 10.1109/ICIPTM59628.2024.10563826.

\*\*\*

### Conditional monitoring and remaining useful life prediction of electric motor in predictive maintenance: review

P. A. Sannikov, Kalashnikov Izhevsk State Technical University, Izhevsk, Russia

P. V. Lekomtsev, Kalashnikov Izhevsk State Technical University, Izhevsk, Russia

*Predictive maintenance of an electric drive as part of technological equipment reduces the probability of unplanned production downtime and minimizes repair costs by continuously monitoring the condition and predicting the remaining useful life of the electric drive. Based on the analysis of foreign sources and ISO standards, the article presents aspects of predictive maintenance systems: the stages of their construction and the methods used at each stage are considered. The emphasis is placed on the most time-consuming and combining various methods of stages - diagnosis of the condition of the electric drive and faults prediction. The methods of determining the technical condition of the electric drive are highlighted, their advantages and disadvantages are considered, as well as the types of faults that can be diagnosed using each of the methods. The most effective and widely used diagnostic methods turned out to be methods based on the analysis of vibration and electrical signals, since they allow detecting a wide range of faults. In addition, they are versatile, as they are suitable for determining the technical condition of almost all types of electric motors. A comparative analysis of machine learning methods used to predict faults and remaining useful life of an electric drive is carried out. Such machine learning methods as the Random Forest method, Long short-term memory neural networks, the support vector machine method, and the k-nearest neighbor method are noted. The analysis showed that the choice of an algorithm depends on many factors and cannot be based on universal approaches.*

**Keywords:** predictive maintenance, condition monitoring, diagnosis, an electric drive, deep learning, classification and regression methods.

Получено: 06.11.24

#### Образец цитирования

Санников П. А., Лекомцев П. В. Определение технического состояния и прогнозирование остаточного ресурса электропривода в предсказательном обслуживании: обзор зарубежных источников // Интеллектуальные системы в производстве. 2025. Т. 23, № 1. С. 82–93. DOI: 10.22213/2410-9304-2025-1-85-93.

#### For Citation

Sannikov P.A., Lekomtsev P.V. [Conditional monitoring and remaining useful life prediction of electric motor in predictive maintenance: review]. *Intellectual'nye sistemy v proizvodstve*. 2025, vol. 25, no. 1, pp. 82-93. DOI: 10.22213/2410-9304-2025-1-85-93.