

## ПРИБОРЫ И МЕТОДЫ ИЗМЕРЕНИЙ

DOI 10.54398/20741707\_2022\_2\_141  
УДК 004.8

### АНАЛИЗ НЕИСПРАВНОСТЕЙ СИНХРОННЫХ ДВИГАТЕЛЕЙ С ПОСТОЯННЫМИ МАГНИТАМИ НА ОСНОВЕ МОНИТОРИНГА ВИБРАЦИИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

*Статья поступила в редакцию 29.04.2022, в окончательном варианте – 13.05.2022.*

**Саксонов Евгений Александрович**, Московский технический университет связи и информатики, 111024, Российская Федерация, г. Москва, ул. Авиамоторная, 8а,

доктор технических наук, профессор, ORCID: 0000-0002-2015-6956, e-mail: saksmiem@mail.ru

**Симонов Сергей Евгеньевич**, Московский технический университет связи и информатики, 111024, Российская Федерация, г. Москва, ул. Авиамоторная, 8а,

аспирант, ORCID: 0000-0003-3391-8064, e-mail: s.e.simonov@mtuci.ru

**Городничев Михаил Геннадьевич**, Московский технический университет связи и информатики, 111024, Российская Федерация, г. Москва, ул. Авиамоторная, 8а,

кандидат технических наук, доцент, ORCID: 0000-0003-1739-9831, e-mail: m.g.gorodnichev@mtuci.ru

**Мосева Марина Сергеевна**, Московский технический университет связи и информатики, 111024, Российская Федерация, г. Москва, ул. Авиамоторная, 8а,

аспирант, ORCID: 0000-0002-9778-124X, e-mail: m.s.moseva@mtuci.ru

Синхронные двигатели с постоянными магнитами становятся все более популярными как в промышленности, так и в электрических и гибридных приводах транспортных средств. К сожалению, данные двигатели, так же как и другие типы двигателей, склонны к износу. В них, как и в приводных системах с асинхронными двигателями, подшипники качения часто выходят из строя. В этой статье рассматриваются возможности обнаружения данного типа механического повреждения путем анализа механических колебаний с использованием нейронных сетей. Для выделения диагностических признаков использовали быстрое преобразование Фурье и преобразование Гильберта (ПГ). Для автоматизации процесса обнаружения неисправностей были протестированы три типа нейронных сетей: много-слойный перцептрон (MLP), нейронная сеть с радиальной базовой функцией (RBF) и карта Кохонена (самоорганизующаяся карта, SOM). Входными сигналами этих сетей служили амплитуды гармонических составляющих, характерных для повреждений опорных элементов, полученные в результате быстрого преобразования Фурье или ПГ-анализа сигнала виброускорения. Эффективность анализируемых структур нейронных сетей сравнивалась с точки зрения влияния архитектуры сети и различных параметров процесса обучения на эффективность обнаружения.

**Ключевые слова:** синхронные двигатели с постоянными магнитами, вибродиагностика, нейронные сети, предиктивная аналитика

### FAULT ANALYSIS OF SYNCHRONOUS MOTORS WITH PERMANENT MAGNETS BASED ON VIBRATION MONITORING USING NEURAL NETWORKS

*The article was received by the editorial board on 29.04.2022, in the final version – 13.05.2022.*

**Saksonov Evgeniy A.**, Moscow Technical University of Communication and Informatics, 8a Aviamotornaya St., Moscow, 111024, Russian Federation,

Doct. Sci. (Engineering), Professor, ORCID: 0000-0002-2015-6956, e-mail: saksmiem@mail.ru

**Simonov Sergey E.**, Moscow Technical University of Communication and Informatics, 8a Aviamotornaya St., Moscow, 111024, Russian Federation,

postgraduate student, ORCID: 0000-0003-3391-8064, e-mail: s.e.simonov@mtuci.ru

**Gorodnichev Mikhail G.**, Moscow Technical University of Communication and Informatics, 8a Aviamotornaya St., Moscow, 111024, Russian Federation,

Cand. Sci. (Engineering), Assistant Professor, ORCID: 0000-0003-1739-9831, e-mail: m.g.gorodnichev@mtuci.ru

**Moseva Marina S.**, Moscow Technical University of Communication and Informatics, 8a Aviamotornaya St., Moscow, 111024, Russian Federation,

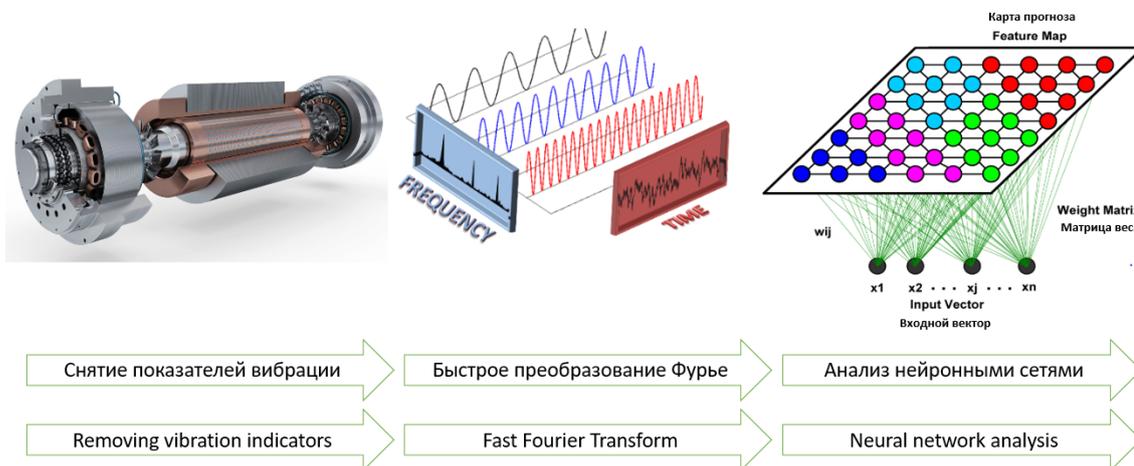
postgraduate student, ORCID: 0000-0002-9778-124X, e-mail: m.s.moseva@mtuci.ru

Permanent magnet synchronous motors are becoming increasingly popular both in industry and in electric and hybrid vehicle drives. Unfortunately, these engines, like other types of engines, are prone to wear. In them, as in drive systems with asynchronous motors, rolling bearings often fail. This article discusses the possibilities of detecting this type of mechanical damage by analyzing mechanical vibrations using neural networks. The fast Fourier transform and the Hilbert transform (TG)

were used to highlight diagnostic features. To automate the fault detection process, three types of neural networks were tested: Multilayer Perceptron (MLP), Radial Basis Function (RBF) Neural Network, and Kohonen Map (Self Organizing Map, SOM). The input signals of these networks were the amplitudes of the harmonic components characteristic of damage to the supporting elements, obtained as a result of the fast Fourier transform or PG analysis of the vibration acceleration signal. The efficiency of the analyzed structures of neural networks was compared in terms of the influence of the network architecture and various parameters of the learning process on the detection efficiency.

**Keywords:** permanent magnet synchronous motors, vibration diagnostics, neural networks, predictive analytics

#### Graphical annotation (Графическая аннотация)



**Введение.** В настоящее время синхронные двигатели с постоянными магнитами (СДПМ) набирают все большую популярность на промышленных предприятиях. Они также широко используются в приводных системах электрических и гибридных транспортных средств. Это связано с их многочисленными преимуществами, такими как высокий КПД, возможность высокой перегрузки по крутящему моменту и высокое отношение мощности к весу. Они хорошо работают в областях, требующих как высокой точности, так и высокой динамики [1, 2]. Не менее важным требованием к современной приводной системе является показатель надежности. Несмотря на очень хорошие рабочие параметры, СДПМ являются не безотказными. Факторами, вызывающими различные повреждения, могут быть: слишком большой ток, высокая рабочая температура, неадекватная смазка или коррозия [2]. Внедрение диагностики приводной системы позволяет обнаруживать повреждения компонентов двигателя уже на начальной стадии их развития. Обычно отказ одного из компонентов приводит к последующим отказам. Мониторинг позволяет планировать замену поврежденной детали и предотвратить выход из строя связанных компонентов. Надлежащая диагностика гарантирует безопасность и продлевает срок службы электромашин [3]. Подшипники качения, рассматриваемые в данной статье, являются наиболее повреждаемыми компонентами двигателей переменного тока средней мощности. На их долю приходится около 40 % всех отказов электрических машин, а на отказы статора, ротора и других – 36 %, 9 % и 14 % соответственно [4]. Подшипники качения отвечают за поддержание постоянного воздушного зазора между ротором и статором. Поэтому их выход из строя постепенно приводит к выходу из строя всей электромашин [3, 4].

Существует множество методов диагностики подшипников двигателей переменного тока. При обнаружении данного вида повреждений в качестве диагностического сигнала чаще всего используют показатели датчиков вибрации [5]. Другими показателями, по которым можно прогнозировать отказы, являются ток [6], скорость [7], шум [8] и температура [9]. Быстрое преобразование Фурье (БПФ) использовалось в [3] как один из методов, который можно использовать для предварительной обработки тока статора в диагностических целях. Метод требует, чтобы обрабатываемый сигнал был стационарным, чего трудно добиться в приводной системе с регулируемой скоростью. Поэтому в ссылках [3] и [10] для переходных состояний (при изменении момента нагрузки) использовалось вейвлет-преобразование. В работе [11] представлен менее часто используемый метод вариационной модовой декомпозиции (VMD), который позволяет выделить компоненты вибрационного сигнала, важные в процессе диагностики, от тех, которые мешают этому процессу. Преобразование Гильберта (HT) использовалось для повышения стабильности обнаружения методом VMD.

Чаще всего авторы сравнивают возможность обнаружения повреждений подшипников качения по нескольким диагностическим сигналам. Например, в работе [12] тестировались три диагностических сигнала: ток статора, скорость вращения ротора и механические вибрации. Симптомы неисправности в данной работе обнаруживались с использованием БПФ и анализа спектра эксцесса, данный метод улучшает отношение сигнал/шум. Испытания включали влияние различных значений частоты вращения и изменение момента нагрузки. Другой подход заключается в сравнительном анализе нескольких методов

обработки одного диагностического сигнала. В работе [13] авторы проанализировали сигнал виброускорения для обнаружения повреждения подшипников качения в приводе бесколлекторного двигателя постоянного тока. В представленном исследовании возможность обнаружения поврежденного подшипника оценивалась с помощью четырех методов обработки сигналов: классического БПФ-сигнала, преобразования Фурье по абсолютному значению сигнала, преобразования Фурье по огибающей сигнала, рассчитанной с помощью преобразования Гильберта, и преобразования Фурье от сигнала, отфильтрованного энергетическим оператором Тигера – Кайзера. Результаты были представлены для трех различных случаев отказа подшипников качения и сравнивались с неповрежденным подшипником. Авторы показали, что использование дополнительного метода обработки сигналов, основанного на преобразовании Гильберта, фильтре ТКЕО (Teager – Kaiser energy operator – энергетический оператор Тигера – Кайзера) или преобразовании по абсолютной величине, позволяет лучше контролировать состояние подшипника. Относительная амплитуда наблюдаемых характерных частот увеличилась в несколько десятков или сотен раз, а в случае ТКЕО – даже в несколько тысяч раз, что упростило распознавание неисправностей.

Поскольку механическая структура двигателей переменного тока (асинхронный двигатель, синхронный двигатель с постоянными магнитами, бесщеточные двигатели постоянного тока) различна, резонансы конструкции также различны. Таким образом, амплитуды одной и той же неисправности могут варьироваться в зависимости от приводной системы машины, и мы получим разные значения амплитуды при разных номерах гармоник, описывающих конкретный подшипник. При этом сама методика диагностики неисправностей будет одинаковой для подшипников качения для разных приводных систем [2, 5, 13, 14]. Основная задача проектировщика диагностической системы состоит в том, чтобы выбрать те гармоники, которые наиболее чувствительны к выбранным типам неисправностей для данной приводной системы.

Применение любого из вышеперечисленных методов обработки сигналов к механическим и/или электрическим сигналам, несущим признаки отказа подшипника, требует анализа и оценки полученных результатов. Необходимы экспертные знания для использования этих симптомов в диагностическом процессе, интерпретации результатов, установления подходящих порогов и проведения регулярного мониторинга данных, получаемых благодаря этим анализам. Такой подход вводит человеческий фактор, что снижает отказоустойчивость всей системы. Поэтому ведутся поиски методов устранения этого человеческого фактора и автоматизации процесса обнаружения неисправности. В настоящее время эту задачу могут выполнить нейронные сети (НС), которые могут выступать в качестве детекторов и/или классификаторов повреждений, сводя к минимуму участие человека в диагностическом процессе [1, 5, 14–23].

В последнее время в исследованиях по обнаружению повреждений подшипников качения в электроприводах переменного тока часто предлагаются глубокие нейронные сети (ГНС), которые набирают все большую популярность в связи с развитием методов глубокого обучения [1, 15, 16]. В работе [1] представлена диагностика подшипников качения привода СДПМ с помощью сверточной нейронной сети (СНС), основанной на измерениях тока статора и сигналов вибрации. Одновременный анализ частотного спектра тока статора и необработанного вибрационного сигнала позволил получить эффективность обнаружения на уровне 96 %. Диагностика только по одному измеренному сигналу привела к снижению эффективности в два раза. В работе [15] метод обучения без учителя на основе глубокого автоэнкодера использовался для классификации трех состояний двигателя СДПМ: неповрежденный, неисправность внешней обмотки подшипника и 10% межвитковое короткое замыкание. Непрерывное вейвлет-преобразование (CWT) использовалось для начальной обработки сигналов тока статора и сигналов механической вибрации. Авторы получили точность классификации при одновременном использовании обоих сигналов на уровне примерно 91 % для сигналов без шума и примерно 88 % для сигналов с шумом. Классификатор, основанный только на текущем сигнале, достиг точности обнаружения примерно 99 % (сигнал без шума) и примерно 75 % для сигнала с шумом, а на основе механических вибраций – примерно 69 % и 66 % соответственно. Авторами [16] представлен классификатор трех состояний двигателя СДПМ: неповрежденное, неисправность по внешнему кольцу подшипника и 10%-ное межвитковое замыкание. В этом случае двигатель работал в условиях переменной скорости и переменного момента нагрузки. Были проанализированы ток статора и механические вибрации, и классификация была выполнена с помощью метода опорных векторов с радиальной базисной функцией Гаусса (RBF) в качестве ядра в методе опорных векторов (SVM). Полученная точность этого классификатора SVM составила примерно 93 %.

Растущий интерес ученых к глубоким нейронным сетям привел к значительно меньшему количеству статей, использующих классические неглубокие нейронные сети (НС) в диагностике привода СДПМ. Однако классические НС имеют ряд важных преимуществ, которые следует учитывать, таких как более простая архитектура, меньшее время обучения и, следовательно, меньшая вычислительная сложность, в том числе меньшие требования к мощности процессоров при практической реализации.

Следует подчеркнуть, что правильно параметризованная классическая нейронная сеть позволяет достичь очень высокого уровня эффективности диагностики электрических машин. Примером такой сети является многослойный перцептрон (MLP), использованный в работе [17], где авторы представляют использование сетей с одним скрытым слоем, обученных с помощью алгоритма дельта-правила, для обнаружения эксцентриситета и повреждения подшипников качения в СДПМ. В качестве диагностического

сигнала использовался ток статора. Эффективность была протестирована для переменных значений скорости и момента нагрузки. Проблема была обработана бинарным способом, поэтому ответ сети показывал только отказ (1) или нормальные (0) условия работы. Наилучшие результаты, 100% эффективность, были получены при самых высоких значениях нагрузки и скорости.

Карты самоорганизации (SOM), также известные как нейронная сеть Кохонена (KNN), тоже использовались в качестве классификаторов повреждений подшипников качения. Диагностика неисправности подшипника с помощью SOM была представлена, например, в ссылке [5]. В данной работе диагностика основывалась на измерении вибрации. Для начальной обработки сигнала использовались БПФ и вейвлет-преобразование. Задачей НС являлась классификация уровней неисправности. Исследование проводилось для пяти различных условий нагрузки, пяти различных скоростей вращения вала и восьми отказов подшипников. Предложенный SOM позволил обнаружить поврежденный подшипник с низкой топологической ошибкой около  $\pm 0,04$ , но с умеренной ошибкой квантования  $\pm 0,5$ .

Пример очень обширной классической НС можно найти в источнике [22]. Авторы разработали трехслойные MLP с 10, 15, 20, 25, 30 и 35 нейронами в скрытом слое соответственно. На входы этих НС помимо двух амплитуд характерных частот повреждения подаются амплитуда частоты вращения, коэффициент эксцесса вибросигнала, максимальное и среднее значения вибросигналов. Нейронная сеть имела три выхода, каждый из которых служил индикатором одной из трех неисправностей: разболтанность подшипника, дефекты внутренней дорожки качения и дефекты тел качения. На выходе получали информацию о техническом состоянии испытуемого элемента подшипника (поврежден или нет). Алгоритм Левенберга – Марквардта использовался для обучения, поддерживаемого методом перекрестной проверки, чтобы улучшить обобщение и избежать переобучения. Несмотря на относительно большее количество нейронов в скрытом слое, представленные детекторы характеризовались средней эффективностью, примерно 86–96 %.

Другой пример использования классических НС состоит в увеличении количества входов сети [23]. Авторы использовали данные измерений из Центра данных подшипников Университета Кейс Вестерн Резерв для обучения самоорганизующейся карты (SOM) с целью классификации повреждений подшипников качения. В качестве входных данных SOM использовались различия 70 признаков, таких как статистические признаки, признаки частотной области, коэффициенты авторегрессионной модели, анализ разложения пакетов вейвлетов и энергия энтропии разложения эмпирических мод. Для выбора оптимальных признаков использовались две методики (алгоритмы расширенного рельефа и алгоритм минимальной избыточности и максимальной релевантности (mRMR)), которые позволили получить до 100% эффективности по 33 признакам. Однако практическая реализация таких расширенных детекторов или классификаторов неисправностей достаточно сложна, особенно при необходимости использования простых процессоров, например, процессоров с архитектурой ARM, а также для применения таких решений в промышленности.

Хотя, как видно из вышеприведенного обзора литературы, имеются примеры использования избранных классических нейронных структур для диагностики подшипников качения в приводах с регулируемой частотой вращения СДПМ, отсутствует сравнение эффективности различных нейронных структур в выявлении и/или классификации отказов подшипников, проводимых для широкого диапазона условий работы такого привода.

Таким образом, целью настоящего исследования является сравнительный анализ эффективности трех выбранных типов ИНС для обнаружения повреждений подшипников качения в приводе СДПМ. Для получения диагностических признаков планируется использовать два метода обработки вибрационного сигнала: быстрое преобразование Фурье (БПФ) и преобразование Гильберта (ПГ) для получения огибающей сигнала, который затем подвергнется анализу БПФ. Предварительный анализ позволит выделить несколько характеристик диагностических признаков выхода из строя подшипников качения. Необходимо сравнить возможности использования MLP-, RBF-сетей и карт Кохонена для выявления и классификации повреждений подшипников. Также необходимо проанализировать два варианта работы детектора НС: первый должен определять наличие повреждения или его отсутствие (детектор неисправности), второй должен определять тип поврежденного элемента конструкции подшипника (классификатор неисправности). Кроме того, необходимо проанализировать влияние топологии НС, функции активации, метода обучения и скорости обучения на эффективность обнаружения/классификации. Предполагалось, что разрабатываемые нейродетекторы и классификаторы должны достигать точности на уровне 95–100 %, но не менее 90 %.

Первая часть этой статьи содержит обзор литературы по диагностике подшипников качения с особым акцентом на приводы СДПМ, а также мотивацию представленного исследования. В следующих двух разделах обсуждаются характеристики повреждения подшипников качения и методы, используемые для анализа начального сигнала. В четвертом разделе кратко охарактеризованы применяемые структуры НС.

**Краткая характеристика признаков неисправности подшипника.** Подшипники качения являются элементами привода, обеспечивающими вращение ротора с минимальными механическими потерями. Подшипники позволяют минимизировать сопротивление движению вала и удерживать его в правильном положении. Поэтому подшипники являются элементами, наиболее интенсивно подверженными процессу изнашивания [3, 4]. Как правило, подшипники качения состоят из разделителя (сепаратора), в котором тела качения размещены и правильно разделены. Сепаратор расположен между внутренним кольцом, которое надевается на вал машины, и наружным кольцом [21]. Конструкция подшипника качения показана на рисунке 1.

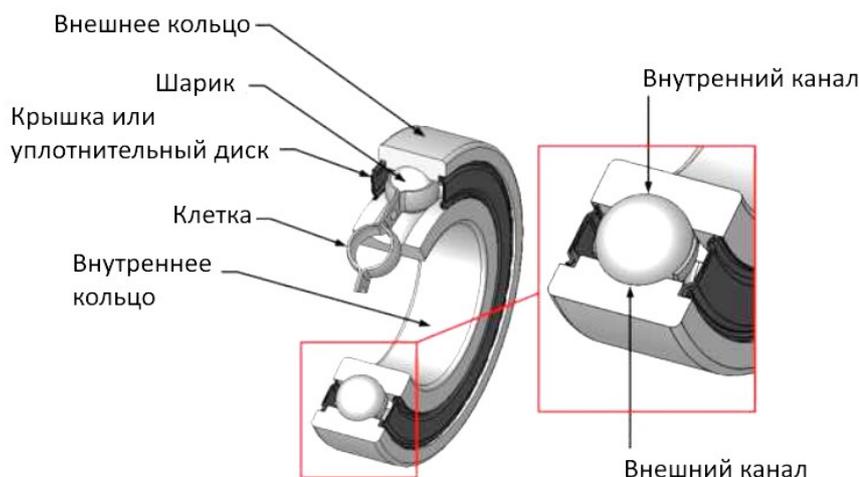


Рисунок 1 – Схема конструкции подшипника качения

По своему характеру повреждения подшипников качения можно разделить на два типа [24, 25]:

- точечные повреждения (выбоины, сколы от мелких осколков);
- диффузные повреждения (деформация поверхности, коррозионные повреждения, неровности).

Оба типа повреждений приводят к разным симптомам. Точечные повреждения вызывают вибрации в низкочастотном диапазоне. Диффузные повреждения обнаруживаются путем наблюдения за спектром вибрации в широком диапазоне. Из-за их природы их трудно описать с точки зрения конкретных частот. Возникновение повреждения и его дальнейшее усугубление вызывает изменение геометрии тел качения, повышение уровня вибрации и шума двигателя при работе и, наряду с их ухудшением, может привести к эксцентриситету ротора в отношении к статору и повреждению механического соединения с работающей машиной. Как и любой элемент электропривода, подшипники имеют длительный срок службы и их естественные повреждения возникают в результате характера и времени эксплуатации. Преждевременные отказы могут возникать по многим причинам. Чаще всего они возникают из-за неправильной сборки, нередко они также вызваны неправильным подбором присоединения к требованиям привода и его неправильной эксплуатацией [26–29]. В зависимости от того, какой именно элемент подшипника поврежден точно, в спектре сигнала механической вибрации проявляются различные признаки повреждения [13, 21, 24, 25].

Признаки, определяющие состояние подшипника, получают путем определения амплитуд характерных частот, встречающихся в спектре вибрации. Значительное увеличение этих амплитуд свидетельствует о точечном повреждении данного элемента. Для расчета характеристических частот необходимо найти частоту вращения вала двигателя  $f_r$ :

$$f_r = \frac{n}{60}, \quad (1)$$

где  $n$  – скорость двигателя (об/мин).

Тогда частоты характерных гармоник при отказах отдельных элементов подшипника можно определить на основании приведенных ниже формул [21, 22, 24]:

$$f_{bc} = \frac{1}{2} f_r \left( 1 - \frac{D_b}{D_c} \cos\beta \right), \quad (2)$$

$$f_{or} = \frac{N_b}{2} f_r \left( 1 - \frac{D_b}{D_c} \cos\beta \right), \quad (3)$$

$$f_{ir} = \frac{N_b}{2} f_r \left( 1 + \frac{D_b}{D_c} \cos\beta \right), \quad (4)$$

$$f_{re} = \frac{D_c}{D_b} f_r \left( 1 - \frac{D_b}{D_c} \cos\beta \right), \quad (5)$$

где  $N_b$  – количество тел качения (шариков);  $D_b$  – диаметр тел качения;  $D_c$  – делительный диаметр подшипника;  $\beta$  – рабочий угол подшипника ( $0^\circ$  для подшипника качения);  $f_{bc}$ ,  $f_{or}$ ,  $f_{ir}$ ,  $f_{re}$  – частоты, характерные для данного отказа: сепаратор подшипника, внешнее кольцо, внутреннее кольцо и тело качения.

Хорошо видно, что частоты характеристических гармоник зависят только от частоты вала (которая в двигателе с постоянным магнитом не зависит от момента нагрузки, в отличие от асинхронного двигателя) и геометрии подшипника качения.

**Методы анализа признаков отказа с использованием вибросигнала.** В данной работе для подготовки входных сигналов разрабатываемых нейродетекторов использовались два метода анализа вибросигнала: классическое быстрое преобразование Фурье (БПФ) и БПФ сигнала огибающей виброускорения, рассчитанного с помощью преобразования Гильберта (ЭНВ).

Классическое БПФ – это преобразование, наиболее часто используемое в диагностике машин. Он преобразует сигнал из временной области в частотную область и в непрерывном виде может быть записан следующим образом [30]:

$$F(j, \omega) = \int_{-\infty}^{+\infty} f(t)e^{-i\omega t} dt. \quad (6)$$

Преобразование Фурье предполагает, что анализируемые сигналы являются периодическими и стационарными, и выполняет декодирование анализируемого сигнала в заданное количество синусоидальных сигналов с заданной частотой составляющих. Реальные сигналы в большинстве случаев не удовлетворяют условиям периодичности и стационарности. Кроме того, сигнал должен дискретизироваться синхронно с основной частотой сигнала в соответствии с теоремой выборки Шеннона. Длина анализируемого фрагмента сигнала должна быть целым числом, кратным периоду его основной гармоники. Для сигналов, отвечающих этим критериям, полученный спектр правильный; в противном случае происходит размытие спектра. Это также связано с неточностью определения амплитуды и может оказывать существенное влияние на интерпретацию результатов. Переход из временной области в частотную означает, что момент появления данной компоненты не влияет на ее место в спектре. Следовательно, сигнал, подвергаемый такому анализу, должен быть стационарным из-за потери временной информации.

Дискретное преобразование Фурье (ДПФ) используется для анализа сигналов [30]:

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi nk}{N}}, \quad (7)$$

где  $x(n)$  – реальные дискретные сигналы конечной длины  $N$ , генерируемые при непрерывной дискретизации сигналов.

Основная форма, используемая для представления результатов после дискретного преобразования Фурье (ДПФ), представляет собой частотный спектр с амплитудами гармоник, рассчитанными согласно:

$$|X(k)| = \sqrt{(\text{Re}\{X(k)\})^2 + (\text{Im}\{X(k)\})^2}. \quad (8)$$

В целях масштабирования спектра в единицах частоты каждый  $|X(k)|$  выборке приписывается частота  $f(k)$ , рассчитанная по следующему выражению:

$$f(k) = k \frac{f_p}{N}, \quad (9)$$

где  $f_p$  – частота дискретизации сигнала, а  $N$  – количество всех выборок сигнала.

**Преобразование Гильберта.** Непрерывное преобразование Гильберта для любого хода времени  $x(t)$  имеет следующий вид [31]:

$$H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t-\tau} d\tau. \quad (10)$$

Аналитический сигнал  $\alpha(t)$ , созданный из реального сигнала  $x(t)$  и его преобразования Гильберта, имеет следующий вид [31]:

$$\alpha(t) = x(t) + jH[x(t)] = a_{ENV}(t)e^{j\varphi(t)}, \quad (11)$$

где  $a_{ENV}(t)$  – мгновенная амплитуда огибающей исходного сигнала  $x(t)$ ,  $j(t)$  – мгновенная фаза [31, 32].

Анализ сигнала  $\alpha_{ENV}(t)$  позволяет найти частоты, характерные для отказов в среднечастотном диапазоне спектра. Для нахождения характерных частот в низкочастотном диапазоне требуется высокое частотное разрешение. Для получения высокого частотного разрешения необходима стационарная работа машины, которую трудно поддерживать в реальных условиях. Характерной особенностью применения преобразования Гильберта является устойчивость к обнаружению вибраций, возникающих из-за других источников, помимо повреждения подшипника. Получается сигнал, из которого также исключается собственная частота диагностируемого двигателя. Это существенное преимущество данной трансформации. ПГ улучшает процесс выделения симптомов и, следовательно, эффективность диагностической системы даже в случае значительных нарушений измеряемого сигнала [31].

Для данного исследования отказов подшипников рассмотрим различные структуры неглубоких нейронных сетей и для последующего сравнения – их эффективность в обнаружении и классификации проанализированных отказов. Рассмотрим следующие неглубокие НС: многослойные перцептроны (MLP), сети с радиальными базовыми функциями (RBF) и самоорганизующиеся карты Кохонена (self-organizing maps, SOM).

**Многослойные перцептроны (MLP – Multilayer Perceptrons).** MLP с прямой связью наиболее популярны в различных промышленных приложениях, они состоят из входного слоя, одного или нескольких скрытых слоев и выходного слоя. Каждый нейрон в каждом слое связан с нейроном следующего слоя; между нейронами одного слоя нет связей, и данные обрабатываются параллельно. Этот тип НС выполняет глобальную аппроксимацию [33, 34]. Это означает, что многие нейроны одновременно решают отобразить каждый элемент входного вектора.

В общем случае сеть MLP можно описать следующим образом:

$$y_k = f_2(\sum_{i=1}^M \omega_{ki}^2 \times f_1(\sum_{j=1}^N \omega_{ij}^1 \times x_j + \omega_0^{(1)}) + \omega_0^{(2)}), \quad (12)$$

где  $y_k$  –  $k$ -е – выход из сети;  $x_j$  –  $j$ -е – вход в сеть;  $\omega_{ij}^{(1)}$ ,  $\omega_{ki}^{(2)}$  – веса первого и второго скрытых слоев соответственно;  $\omega_0^{(1)}$ ,  $\omega_0^{(2)}$  – смещения в первом и втором скрытых слоях соответственно.

Процесс обучения сети MLP состоит из модификации весов таким образом, чтобы минимизировать целевую функцию, обычно среднеквадратичную ошибку выходного значения по отношению к ожидаемому значению. В этой работе для обучения сетей MLP использовался алгоритм Левенберга – Марквардта (LM) [35, 36], который сочетает в себе итерационные особенности метода оптимизации алгоритма Гаусса – Ньютона и алгоритма наискорейшего спуска. Благодаря этому мы получили инструмент, который работает как градиентный спуск, когда мы находимся далеко от минимума целевой функции, а затем сводится к методу сопряженных градиентов. Общая форма алгоритма обучения LM описывается уравнением (13) [35, 37, 38]:

$$\omega_{n+1} = \omega_n - \eta(J_n^T J_n + \mu I)^{-1} J_n e_n, \quad (13)$$

где  $\omega_n$  – вес сети;  $\mu$  – коэффициент регуляризации, определяющий работу алгоритма;  $J_n$  – матрица Якоби,  $e_n$  – ошибка объединения;  $\eta$  – скорость обучения.

Отличие формул Ньютона состоит в добавлении единичной матрицы, умноженной на коэффициент регуляризации  $\mu$ . Он всегда имеет положительное значение, изменяющееся в процессе обучения. Изменяя этот коэффициент, мы непрерывно переходим от метода алгоритма наискорейшего спуска к методу развёртывания Ньютона. Для значений, близких к нулю, алгоритм вычисляет веса аналогично методу развёртывания Ньютона. Увеличение значения  $\mu$  сопровождается увеличением значимости направления улучшения, определяемого на основе градиента функции ошибок. Помимо определения доли отдельных стратегий в получаемом результате,  $\mu$  также выполняет функцию величины шага в сторону улучшения [35, 37, 38].

Алгоритм Левенберга – Марквардта очень чувствителен к инициализации весовых значений, поскольку они выбираются случайным образом. Улучшение вышеописанного метода заключается в добавлении байесовской регуляризации. Это улучшает обобщающие свойства сети. Регуляризация вносит изменение в целевую функцию. Цель состоит не только в минимизации среднеквадратичной ошибки, но и в достижении ее с наименьшими возможными весами. Целевая функция принимает следующий вид [39, 40]:

$$C = \beta E + \alpha E_\omega, \quad (14)$$

где  $E$  – сумма среднеквадратичных ошибок;  $E_\omega$  – сумма квадратов весов;  $\beta$  – фактор обучения;  $\alpha$  – скорость отказа.

Фактор  $\alpha$  обеспечивает низкие значения веса, что значительно снижает склонность сети к переобучению. Эта модификация также обеспечивает большую устойчивость к шуму и некорректным входным данным, но занимает больше времени [39, 40].

**Сети с радиальным основанием.** Рассмотрим радиальные сети (радиальные базисные функции, RBF), т.е. нейронные сети прямого распространения с одним скрытым слоем, в котором функции активации являются радиальными. Каждый элемент входного вектора отображается определенным радиальным нейроном скрытого слоя. Нейроны выходного слоя являются линейными и отвечают за суммирование выходов отдельных нейронов скрытого слоя. Структура сети RBF показана на рисунке 2.

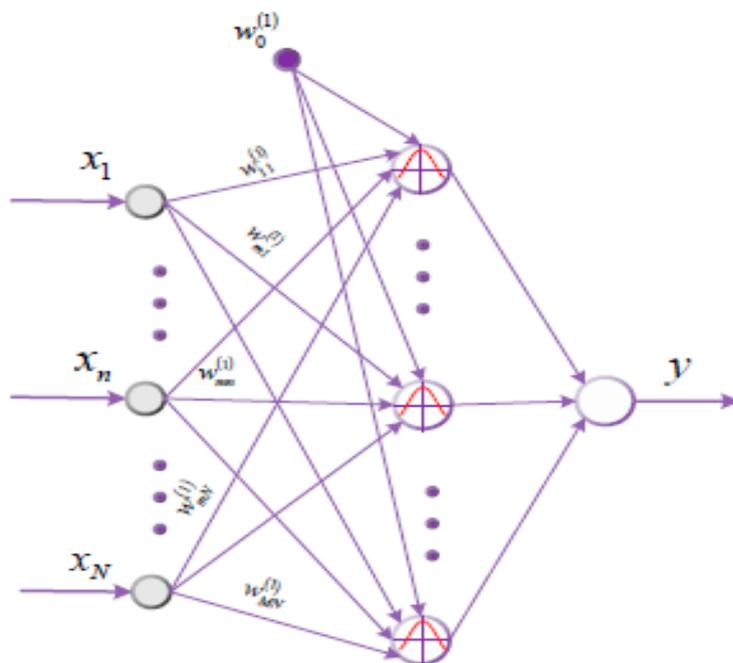


Рисунок 2 – Общая структура сети с радиальной базисной функцией (RBF)

В отличие от сетей MLP, нейроны которых выполняют задачу глобальной стохастической аппроксимации функций многих переменных, в сетях RBF отображение полного набора входных данных представляет собой сумму локальных отображений [34]. Выходные значения RBF-сети получаются как сумма произведений выходов зубчатых RBF-нейронов и весовых коэффициентов:

$$y_k = \sum_{j=1}^N \omega_{jk} \varphi_j + \omega_{k0} \quad (15)$$

с вычисленными выходами нейронов RBF, полученными следующим образом:

$$\varphi_j = \exp\left(-\frac{v_j^2(X)}{2\sigma_j^2}\right), \quad (16)$$

где  $y_k$  –  $k$ -й выход зубчатой сети;  $\omega_{jk}$  – весовой коэффициент между  $\sigma$ -м выходом скрытого (RBF) слоя и  $k$ -м нейроном выхода НС;  $\omega_{k0}$  – смещение  $k$ -го выходного нейрона;  $v_j^2(X)$  – значения входного вектора евклидова расстояния и центры функций RBF;  $\sigma$  – коэффициент разброса функции активации.

Рассчитываются евклидовы расстояния между значениями входного вектора и центрами функций RBF:

$$v_j(X) = \|X - C_j\| = \sqrt{\sum_{k=1}^N (x_k - c_k)^2}, \quad k = 1, 2, 3, \dots, N, \quad (17)$$

где  $X = [x_1, x_2, x_3, \dots, x_N]^T$  – входной вектор;  $C_j$  – вектор, относящийся к центру каждого нейрона RBF.

Процесс проектирования для сетей RBF намного проще, чем для MLP. Процедура обучения состоит из трех этапов, которые включают [41]:

- выбор центров  $C_j$  скрытых радиальных базисных нейронов;
- выбор параметра разброса,  $\sigma$  – ширина радиальной функции для каждого скрытого нейрона;
- определение весовых коэффициентов  $\omega_{jk}$  между скрытым (радиальным) и выходным слоями.

Первый этап может выполняться случайным образом с равномерным распределением. Для более сложных задач используются алгоритмы кластеризации данных. Наиболее популярен алгоритм  $k$ -средних [41]. Этот алгоритм требует определения числа кластеров сверху вниз. В общем, алгоритм  $k$ -средних направлен на размещение центров нейронов RBF в областях с наиболее значимыми данными [42, 43]. Веса нанесенного слоя определяются методом обучения с учителем, например, по дельта-правилу. Скорость обучения намного короче, поэтому проблема локального минимума снимается.

**Карты Кохонена.** Последними структурами нейронной сети, рассматриваемыми в данной работе для обнаружения повреждений подшипников качения, являются самоорганизующиеся карты (СОМ). Сетевое обучение основано на встроенном механизме конкуренции и оценки соседства. SOM образован входным и выходным (конкурентным) слоями. Конструкция менее сложна, чем сети MLP и RBF из-за отсутствия скрытого слоя.

Данная НС также является сетью с прямой связью, и каждый элемент входного слоя связан с каждым элементом выходного слоя. Выходной сигнал  $y_k$   $k$ -го нейрона описывается векторной зависимостью:

$$y_k = W^T X = \|W\| \|X\| \cos \phi_k.$$

Поскольку три входных вектора  $X$  и веса  $W$  нормированы в сети, выходное значение  $y_k$  (активация нейрона) определяется угловой разницей  $\phi_k$  между векторами  $X$  и  $W$ .

Самоорганизующиеся сети позволяют находить неизвестные связи между входными данными, что возможно с использованием двух методов обучения: «Победитель получает все» (WTA) и «Победитель получает больше всего» (WTM). В методе WTA адаптируется только нейрон-победитель. Адаптация заключается в приближении нейрона-победителя к входному паттерну. Алгоритм WTM предполагает, что также могут быть активированы нейроны из должным образом заданного соседства (например, функция соседства Гаусса) (адаптация веса). Обычно в качестве меры окрестности берется евклидово расстояние [44–46].

**Испытание ИНС.** Для проведения сравнительного анализа эффективности выбранных ИНС с целью выявления и прогнозирования повреждения подшипников качения в СДПМ необходимо промоделировать поведение измерений показателей вибрации, температуры и электрических параметров СДПМ.

Похожая работа по сравнительному анализу представленных нейросетей была проделана в [50]. Согласно этой работе использовался испытательный стенд на основе двух моторов и частотного преобразователя. На данном испытательном стенде были использованы исходные данные измерений, полученные в разработанной авторами лабораторной установке, работающей на основе частотного преобразователя, находящегося в режиме векторного управления, так как это обычно происходит в реальных промышленных условиях. Авторы отказались от использования общедоступных баз данных, анализ которых был представлен в многочисленных статьях. Измерения проводились с использованием измерительной карты и компьютера. Измерения вибрации проводились для подшипников с моделируемыми повреждениями внешних и внутренних дорожек качения и тел качения, а также для подшипников без дефектов с использованием акселерометров. Кроме того, испытуемые подшипники были повреждены искровым скачком к выбранному элементу (электрический разряд между электродом и поврежденным элементом), аналогичным [1, 8, 13, 31]. В литературе отказы подшипников часто представлены срезом дорожки качения или отверстием, выполненным в поврежденной дорожке качения [7, 13, 17, 18, 23, 25]. В данной статье в качестве диагностического сигнала было использовано виброускорение, измеренное по трем осям. На основании анализа результатов измерений было установлено, что наибольшая реакция на повреждение подшипника была видна

в сигнале по оси X, поэтому только этот сигнал использовался для дальнейшего анализа. Измерения проводились в трех сериях с переменной частотой питающего напряжения и переменным моментом нагрузки. Две серии были использованы для изучения ИНС, а третья – для их тестирования.

Использование преобразования Фурье позволило определить амплитуды характерных частот отказов с помощью приложения, разработанного в симуляционной среде. Проанализированы амплитуды 32 гармоник с частотами, связанными с повреждением внутреннего кольца, внешнего кольца и элемента качения.

Амплитуды 32 гармоник с частотами, связанными с повреждением внутреннего кольца, внешнего кольца и элемента качения, были проанализированы с точки зрения их чувствительности к конкретному повреждению подшипника. Детальный анализ позволил выделить симптомы, которые наиболее сильно реагировали на выбранный тип поврежденного конструктивного элемента подшипника. Было проверено, как влияет момент нагрузки и частота питающего напряжения на выбранные симптомы. Для учета изменчивости момента нагрузки частота вращения  $f_r$  была выбрана в качестве вспомогательного параметра. Если этого не сделать, то тестируемые структуры были бы очень сложными. Кроме того, они потребовали бы большого количества нейронов в скрытых слоях. На этой основе был выбран первый 7-элементный входной вектор ИНС, состоящий из амплитуд характеристических гармоник с частотами отказа, для которых наблюдалось значительное увеличение значения при возникновении отказа. При этом выделенные гармоники характеризовались определенной закономерностью с увеличением частоты питания  $f_s$  или изменением значения момента нагрузки.

Второй входной вектор был разработан на основе ГП-анализа сигнала виброускорения и следующего БПФ полученной огибающей, рассчитанной по уравнению (12). После применения преобразования Гильберта сигнала произошло значительное увеличение амплитудных значений гармоник с частотами, характерными для отдельных отказов.

**Заключение.** Применение классических ИНС в диагностике подшипников качения синхронного двигателя с постоянными магнитами позволяет автоматизировать процесс диагностики неисправностей. Этот инструмент не требует ни математической модели, ни участия человека-эксперта в процессе диагностики, что является его существенными преимуществами.

В случае классификатора неисправностей достижение 100% эффективности требовало более сложной структуры. Одного скрытого слоя оказалось недостаточно для исследуемой проблемы. Наилучшие результаты были получены методом обучения Левенберга – Марквардта с байесовской регуляризацией и логарифмически-сигмоидной функцией активации. Классическая MLP-сеть обеспечила наилучшую эффективность и наименьшие отклонения от ожидаемого значения из всех исследованных структур, особенно для обучающих данных, полученных при анализе сигнала виброускорения с использованием преобразования Гильберта.

Сети с радиальными базисными функциями характеризуются повторяемостью откликов для структур с одинаковыми параметрами и одним и тем же входным вектором для каждого последующего процесса обучения. Это связано с тем, что начальные веса выбираются на основе входного вектора, а не случайным образом, как в MLP-сетях. По этой причине выбор параметров сети RBF занимает меньше времени.

Использование карт Кохонена не полностью автоматизирует процесс диагностики. В этом случае необходимо использовать оценку человека-оператора или добавить алгоритм, который будет отвечать за дополнительный анализ результата, полученного SOM. Тем не менее карты Кохонена кажутся наиболее интересными для дальнейшего исследования всех протестированных структур. Алгоритм k-means чаще всего используется для автоматизации процесса классификации результатов [48, 49]. Выходы сети Кохонена также могут быть входами для других сетей, что обеспечит полную автоматизацию процесса, как это предложено в статье [47]. Для таких целей исследования могут проводиться как с сетями MLP, так и с сетями RBF. Важным преимуществом использования карт Кохонена является отсутствие сложностей в выборе их параметров.

Отрасль нуждается в решениях, обеспечивающих эффективный и автоматизированный процесс диагностики. Предлагаемые ИНС могут быть легко реализованы с использованием малобюджетной интегрированной аппаратной платформы на базе, например, Arm Cortex-M или аналогичных процессоров, либо диагностика может быть основана на существующей в отрасли измерительной инфраструктуре и ее расширении дополнительными нейронными детекторами. Примерная концепция дешевой диагностической системы представлена в [14].

#### Библиографический список

1. Ullah, Z. Detection and Identification of Demagnetization and Bearing Faults in PMSM Using Transfer Learning-Based VGG / Z. Ullah, B. A. Lodhi, J. Hur // *Energies*. – 2020. – Vol. 13. – P. 3834.
2. Chen, Y. Faults and Diagnosis Methods of Permanent Magnet Synchronous Motors: A Review / Y. Chen, S. Liang, W. Li, H. Liang, C. Wang // *Appl. Sci.* – 2019. – Vol. 9. – P. 2116.
3. Rosero, J. Fault Detection in dynamic conditions by means of Discrete Wavelet Decomposition for PMSM running under Bearing Damage / J. Rosero, L. Romeral, E. Rosero, J. Urresty // *Proceedings of the 2009 Twenty-Fourth Annual IEEE Applied Power Electronics Conference and Exposition, Washington, DC, USA, 15–19 February 2009*. – P. 951–956.

4. He, J. Diagnosis of stator winding short-circuit faults in an interior permanent magnet synchronous machine / J. He, C. Somogyi, A. Strandt, N. A. O. Demerdash // Proceedings of the 2014 IEEE Energy Conversion Congress and Exposition (ECCE), Pittsburgh, PA, USA, 14–18 September 2014. – P. 3125–3130.
5. Nkuna, J. S. R. Vibration Condition Monitoring and Fault Classification of Rolling Element Bearings Utilising Kohonen's Self-organising Maps : Theses and Dissertations (Mechanical Engineering). Ph.D. Thesis. – Vanderbijlpark, South Africa : Vaal University of Technology, 2013.
6. Picot, A. Statistic-based spectral indicator for bearing fault detection in permanent-magnet synchronous machines using the stator current / A. Picot, Z. Obeid, J. Regnier, S. Poignant, O. Darnis, P. Maussion // Mech. Syst. Signal Process. – 2014. – Vol. 46. – P. 424–441.
7. Ye, M.; Huang, J. Bearing Fault Diagnosis under Time-Varying Speed and Load Conditions via Speed Sensorless Algorithm and Angular Resample / M. Ye, J. Huang // Proceedings of the 2018 XIII International Conference on Electrical Machines (ICEM), Alexandroupoli, Greece, 3–6 September 2018. – P. 1775–1781.
8. Lu, S.; He, Q.; Zhao, J. Bearing fault diagnosis of a permanent magnet synchronous motor via a fast and online order analysis method in an embedded system / S. Lu, Q. He, J. Zhao // Mech. Syst. Signal Process. – 2018. – Vol. 113. – P. 36–49.
9. Nembhard, A. D.; Sinha, J. K.; Pinkerton, A. J.; Elbhah, K. Fault diagnosis of rotating machines using vibration and bearing temperature measurements / A. D. Nembhard, J. K. Sinha, A. J. Pinkerton, K. Elbhah // Diagnostyka. – 2013. – Vol. 14. – P. 45–51.
10. Rosero, J. PMSM Bearing Fault Detection by means of Fourier and Wavelet transform / J. Rosero, J. Cusido, J. A. Ortega, L. Romeral, A. Garcia // Proceedings of the IECON 2007 – 33rd Annual Conference of the IEEE Industrial Electronics Society, Taipei, Taiwan, 5–8 November 2007. – P. 1163–1168.
11. Liu, H. Fault Diagnosis for a Bearing Rolling Element Using Improved VMD and HT / H. Liu, D. Li, Y. Yuan, S. Zhang, H. Zhao, W. Deng // Appl. Sci. – 2019. – Vol. 9. – P. 1439.
12. Ren, B. Fault Diagnosis of Motor Bearing Based on Speed Signal Kurtosis Spectrum Analysis / B. Ren, M. Yang, N. Chai, Y. Li, D. Xu // Proceedings of the 2019 22nd International Conference on Electrical Machines and Systems (ICEMS), Harbin, China, 11–14 August 2019. – P. 1–6.
13. Skora, M. Selected Rolling Bearing Fault Diagnostic Methods in Wheel Embedded Permanent Magnet Brushless Direct Current Motors / M. Skora, P. Ewert, C. T. Kowalski // Energies. – 2019. – Vol. 12. – P. 4212.
14. Ewert, P. Low-Cost Monitoring and Diagnosis System for Rolling Bearing Faults of the Induction Motor Based on Neural Network Approach / P. Ewert, C. T. Kowalski, T. Orłowska-Kowalska // Electronics. – 2020. – Vol. 9. – P. 1334.
15. Senanayaka, J. S. L. A robust method for detection and classification of permanent magnet synchronous motor faults: Deep autoencoders and data fusion approach / J. S. L. Senanayaka, V. K. Huynh, K. G. Robbersmyr // J. Phys. Conf. Ser. – 2018. – Vol. 1037. – P. 032029.
16. Senanayaka, J. S. L. Fault detection and classification of permanent magnet synchronous motor in variable load and speed conditions using order tracking and machine learning / J. S. L. Senanayaka, V. K. Huynh, K. G. Robbersmyr // J. Phys. Conf. Ser. – 2018. – Vol. 1037. – P. 032028.
17. Akar, M. Mechanical fault detection in permanent magnet synchronous motors using equal width discretization-based probability distribution and a neural network model / M. Akar, M. Hekim, U. Orhan // Turk. J. Electr. Eng. Comput. Sci. – 2015. – Vol. 23. – P. 813–823.
18. Pandarakone, S. E.; Mizuno, Y.; Nakamura, H. Distinct Fault Analysis of Induction Motor Bearing Using Frequency Spectrum Determination and Support Vector Machine / S. E. Pandarakone, Y. Mizuno, H. Nakamura // IEEE Trans. Ind. Appl. – 2017. – Vol. 53. – P. 3049–3056.
19. Navasari, E. Detection Of Induction Motor Bearing Damage With Starting Current Analysis Using Wavelet Discrete Transform And Artificial Neural Network / E. Navasari, D. A. Asfani, M. Y. Negara // Proceedings of the 2018 10th International Conference on Information Technology and Electrical Engineering (ICITEE), Kuta, Indonesia, 24–26 July, 2018. – P. 316–319.
20. Hoang, D. T. A Motor Current Signal-Based Bearing Fault Diagnosis Using Deep Learning and Information Fusion / D. T. Hoang, H. J. Kang // IEEE Trans. Instrum. Meas. – 2020. – Vol. 69. – P. 3325–3333.
21. Zhou, J. Fault detection of rolling bearing based on FFT and classification / J. Zhou, Y. Qin, L. Kou, M. Yuwono, S. SU // J. Adv. Mech. Des. Syst. Manuf. – 2015. – Vol. 9.
22. Li, B. Neural-Network-Based Motor Rolling Bearing Fault Diagnosis / B. Li, M.-Y. Chow, Y. Tipsuwan, J. C. Hung // IEEE Trans. Ind. Electron. – 2000. – Vol. 47. – P. 1060–1069.
23. Haroun, S.; Nait Seghir, A.; Touati, S. Feature Selection for Enhancement of Bearing Fault Detection and Diagnosis Based on Self-Organizing Map / S. Haroun, A. Nait Seghir, S. Touati // Recent Advances in Electrical Engineering and Control Applications. Lecture Notes in Electrical Engineering. – Cham, Switzerland : Springer, 2017. – Vol. 411.
24. Tandon, N. A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings / N. Tandon, A. Choudhury // Tribol. Int. – 1999. – Vol. 32. – P. 469–480.
25. Zandi, O. Brushless DC Motor Bearing Fault Detection Using Hall Effect Sensors and a Two-Stage Wavelet Transform / O. Zandi, J. Poshtan // Proceedings of the 26th Iranian Conference on Electrical Engineering (ICEE2018), Mashhad, Iran, 8–10 May 2018. – P. 827–833.
26. Liu, Z. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings / Z. Liu, L. Zhang // Measurement. – 2020. – Vol. 149. – P. 107002.
27. Rolling Bearings – Damage and Failures – Terms, Characteristics and Causes. – Geneva, Switzerland : International Organization for Standardization, 2017. – ISO 15243:2017 ; publication date: March 2017.
28. Radu, C. The Most Common Causes of Bearing Failure and the Importance of Bearing Lubrication. RKB Technical Review / C. Radu. – February 2010. – P. 1–7. – Режим доступа: <https://www.rkbbearings.com/en/publications.php#sec12>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения: 23.12.2020).
29. Bearing Damage and Failure Analysis, SKF Group, PUB BU/13 14219/2 EN. – June 2017. – P. 1–106. – Режим доступа: [https://www.skf.com/binaries/pub12/Images/0901d1968064c148-Bearing-failures---14219\\_2-EN\\_tcm\\_12-297619.pdf](https://www.skf.com/binaries/pub12/Images/0901d1968064c148-Bearing-failures---14219_2-EN_tcm_12-297619.pdf), свободный. – Заглавие с экрана. – Яз. англ. (дата обращения: 23.12.2020).

30. Smith, S. W. *Digital Signal Processing: A Practical Guide for Engineers and Scientists* / S. W. Smith. – Burlington, VT, USA : Elsevier Science, 2002.
31. Lee, C.-Y. Bearing damage detection of BLDC motors based on current envelope analysis / C.-Y. Lee, Y.-H. Hsieh // *Meas. Sci. Rev.* – 2012. – Vol. 12. – P. 290–295.
32. Espinosa, A. G. Fault Detection by Means of Hilbert-Huang Transform of the Stator Current in a PMSM With Demagnetization / A. G. Espinosa, J. A. Rosero, J. Cusid'o, L. Romeral, J. A. Ortega // *IEEE Trans. Energy Convers.* – 2010. – Vol. 25. – P. 312–318.
33. Bishop, M. C. *Neural Networks for Pattern Recognition* / M. C. Bishop. – 1st ed. – New York, NY, USA : Oxford University Press, 1996.
34. Haykin, S. *Neural Networks, a Comprehensive Foundation* / S. Haykin. – New York, USA : Macmillan College Publishing Company, 1994.
35. Yu, H. Levenberg-Marquardt Training / H. Yu, B. M. Wilamowski // *Industrial Electronics Handbook*. – 2nd ed. – Boca Raton, FL, USA : Intelligent Systems, CRC Press, 2011. – Chapter 12, Vol. 5. – P. 12–1–12–15.
36. Demuth, H. *Neural Network Toolbox – User's Guide. Version 4* / H. Demuth, M. Beale. – Natick, MA, USA : The MathWorks, Inc., 2004.
37. Du, Y.-C. Levenberg-Marquardt Neural Network Algorithm for Degree of Arteriovenous Fistula Stenosis Classification Using a Dual Optical Photoplethysmography Sensor / Y.-C. Du, A. Stephanus // *Sensors*. – 2018. – Vol. 18. – P. 2322.
38. Zayani, R. Levenberg-Marquardt learning neural network for adaptive predistortion for time-varying HPA with memory in OFDM systems / R. Zayani, R. Bouallegue, D. Roviras // *Proceedings of the EUSIPCO2008 – 16th European Signal Processing Conference, Lausanne, Switzerland, 25–29 August 2008*. – P. 1–6. – Режим доступа: <https://hal.archives-ouvertes.fr/hal-02457894>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения: 09.12.2020).
39. Jazayeri, K. Comparative Analysis of Levenberg-Marquardt and Bayesian Regularization Backpropagation Algorithms in Photovoltaic Power Estimation Using Artificial Neural Network / K. Jazayeri, M. Jazayeri, S. Uysal // *Advances in Data Mining. Applications and Theoretical Aspects. ICDM 2016*. – Cham, Switzerland : Springer, 2016. – Vol. 9728.
40. Suliman, A. Applying Bayesian Regularization for Acceleration of Levenberg-Marquardt based Neural Network Training / A. Suliman, B. S. Omarov // *Int. J. Interact. Multimed. Artif. Intell.* – 2018. – Vol. 5. – P. 68–72.
41. Gil, D. Supervised SOM Based Architecture versus Multilayer Perceptron and RBF Networks / D. Gil, M. Johnsson // *Proceedings of the 26th Annual Workshop of the Swedish Artificial Intelligence Society (SAIS), Uppsala, Sweden, 20–21 May 2010*. – P. 15–24.
42. Bayram, S. Comparison of multilayer perceptron (MLP) and radial basis function (RBF) for construction cost estimation: The case of Turkey / S. Bayram, M. E. Ocal, E. Laptali Oral, C. D. Atis // *J. Civ. Eng. Manag.* – 2016. – Vol. 22. – P. 480–490.
43. Fath, A. H. Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems / A. H. Fath, F. Madanifar, M. Abbasi // *Petroleum*. – 2020. – Vol. 6. – P. 80–91.
44. Jaganathan, B. Optimal parameters estimation of a BLDC motor by Kohonen's Self Organizing Map Method / B. Jaganathan, S. Venkatesh, Y. Bhardwaj, V. Sridhar // *Proceedings of the 2011 IEEE Recent Advances in Intelligent Computational Systems, Trivandrum, Kerala, India, 22–24 September 2011*. – P. 068–071.
45. Jacobs, S. Self-organizing maps for monitoring parameter deterioration of DC and AC motors / S. Jacobs, F. Rios-Gutierrez // *Proceedings of the 2013 Proceedings of IEEE Southeastcon, Jacksonville, FL, USA, 4–7 April 2013*. – P. 1–6.
46. Khalifaoui, N. The SOM tool in mechanical fault detection over an electric asynchronous drive. / N. Khalifaoui, M. S. Salhi, H. Amiri // *Proceedings of the 2016 4th International Conference on Control Engineering & Information Technology (CEIT), Hammamet, Tunisia, 16–18 December 2016*. – P. 1–6.
47. Skowron, M.; Orłowska-Kowalska, T. Efficiency of cascade-connected neural networks in detecting initial faults to induction motor drive electric windings / M. Skowron, T. Orłowska-Kowalska // *Electronics*. – 2020. – Vol. 9. – P. 1314.
48. Dogan, Y. SOM++: Integration of Self-Organizing Map and K-Means++ Algorithms / Y. Dogan, D. Birant, A. Kut // *Machine Learning and Data Mining in Pattern Recognition. MLDM 2013*. – Berlin/Heidelberg, Germany : Springer, 2013. – Vol. 7988.
49. Bataineh, A. K. K-Means Clustering in WSN with Kohonen SOM and Conscience Function / A. K. Bataineh, M. H. Samkari, A. Abdulla, S. Al-Azzam // *Mod. Appl. Sci.* – 2019. – Vol. 13. – P. 63–75.
50. Ewert, P.; Orłowska-Kowalska, T.; Jankowska, K. Effectiveness Analysis of PMSM Motor Rolling Bearing Fault Detectors Based on Vibration Analysis and Shallow Neural Networks / P. Ewert, T. Orłowska-Kowalska, K. Jankowska // *Energies*. – 2021. – Vol. 14. – P. 712.

#### References

1. Ullah, Z., Lodhi, B. A., Hur, J. Detection and Identification of Demagnetization and Bearing Faults in PMSM Using Transfer Learning-Based VGG. *Energies*, 2020, vol. 13, p. 3834.
2. Chen, Y., Liang, S., Li, W., Liang, H., Wang, C. Faults and Diagnosis Methods of Permanent Magnet Synchronous Motors: A Review. *Appl. Sci.*, 2019, vol. 9, p. 2116.
3. Rosero, J., Romeral, L., Rosero, E., Urresty, J. Fault Detection in dynamic conditions by means of Discrete Wavelet Decomposition for PMSM running under Bearing Damage. *Proceedings of the 2009 Twenty-Fourth Annual IEEE Applied Power Electronics Conference and Exposition, Washington, DC, USA, 15–19 February 2009*, pp. 951–956.
4. He, J., Somogyi, C., Strandt, A., Demerdash, N. A. O. Diagnosis of stator winding short-circuit faults in an interior permanent magnet synchronous machine. *Proceedings of the 2014 IEEE Energy Conversion Congress and Exposition (ECCE), Pittsburgh, PA, USA, 14–18 September 2014*, pp. 3125–3130.
5. Nkuna, J. S. R. *Vibration Condition Monitoring and Fault Classification of Rolling Element Bearings Utilising Kohonen's Self-organising Maps : Theses and Dissertations (Mechanical Engineering). Ph.D. Thesis.* Vanderbijlpark, South Africa, Vaal University of Technology, 2013.
6. Picot, A., Obeid, Z., Regnier, J., Poignant, S., Darnis, O., Maussion, P. Statistic-based spectral indicator for bearing fault detection in permanent-magnet synchronous machines using the stator current. *Mech. Syst. Signal Process.*, 2014, vol. 46, pp. 424–441.

7. Ye, M., Huang, J. Bearing Fault Diagnosis under Time-Varying Speed and Load Conditions via Speed Sensorless Algorithm and Angular Resample. *Proceedings of the 2018 XIII International Conference on Electrical Machines (ICEM), Alexandroupoli, Greece, 3–6 September 2018*, pp. 1775–1781.
8. Lu, S., He, Q., Zhao, J. Bearing fault diagnosis of a permanent magnet synchronous motor via a fast and online order analysis method in an embedded system. *Mech. Syst. Signal Process.*, 2018, vol. 113, pp. 36–49.
9. Nembhard, A. D., Sinha, J. K., Pinkerton, A. J., Elbhah, K. Fault diagnosis of rotating machines using vibration and bearing temperature measurements. *Diagnostyka*, 2013, vol. 14, pp. 45–51.
10. Rosero, J., Cusido, J., Ortega, J. A., Romeral, L., Garcia, A. PMSM Bearing Fault Detection by means of Fourier and Wavelet transform. *Proceedings of the IECON 2007 – 33rd Annual Conference of the IEEE Industrial Electronics Society, Taipei, Taiwan, 5–8 November 2007*, pp. 1163–1168.
11. Liu, H., Li, D., Yuan, Y., Zhang, S., Zhao, H., Deng, W. Fault Diagnosis for a Bearing Rolling Element Using Improved VMD and HT. *Appl. Sci.*, 2019, vol. 9, p. 1439.
12. Ren, B., Yang, M., Chai, N., Li, Y., Xu, D. Fault Diagnosis of Motor Bearing Based on Speed Signal Kurtosis Spectrum Analysis. *Proceedings of the 2019 22nd International Conference on Electrical Machines and Systems (ICEMS), Harbin, China, 11–14 August 2019*, pp. 1–6.
13. Skora, M., Ewert, P., Kowalski, C. T. Selected Rolling Bearing Fault Diagnostic Methods in Wheel Embedded Permanent Magnet Brushless Direct Current Motors. *Energies*, 2019, vol. 12, p. 4212.
14. Ewert, P., Kowalski, C. T., Orłowska-Kowalska, T. Low-Cost Monitoring and Diagnosis System for Rolling Bearing Faults of the Induction Motor Based on Neural Network Approach. *Electronics*, 2020, vol. 9, p. 1334.
15. Senanayaka, J. S. L., Huynh, V. K., Robbersmyr, K. G. A robust method for detection and classification of permanent magnet synchronous motor faults: Deep autoencoders and data fusion approach. *J. Phys. Conf. Ser.*, 2018, vol. 1037, p. 032029.
16. Senanayaka, J. S. L., Huynh, V. K., Robbersmyr, K. G. Fault detection and classification of permanent magnet synchronous motor in variable load and speed conditions using order tracking and machine learning. *J. Phys. Conf. Ser.*, 2018, vol. 1037, p. 032028.
17. Akar, M., Hekim, M., Orhan, U. Mechanical fault detection in permanent magnet synchronous motors using equal width discretization-based probability distribution and a neural network model. *Turk. J. Electr. Eng. Comput. Sci.*, 2015, vol. 23, pp. 813–823.
18. Pandarakone, S. E., Mizuno, Y., Nakamura, H. Distinct Fault Analysis of Induction Motor Bearing Using Frequency Spectrum Determination and Support Vector Machine. *IEEE Trans. Ind. Appl.*, 2017, vol. 53, pp. 3049–3056.
19. Navasari, E., Asfani, D. A., Negara, M. Y. Detection Of Induction Motor Bearing Damage With Starting Current Analysis Using Wavelet Discrete Transform And Artificial Neural Network. *Proceedings of the 2018 10th International Conference on Information Technology and Electrical Engineering (ICITEE), Kuta, Indonesia, 24–26 July 2018*, pp. 316–319.
20. Hoang, D. T., Kang, H. J. A Motor Current Signal-Based Bearing Fault Diagnosis Using Deep Learning and Information Fusion. *IEEE Trans. Instrum. Meas.*, 2020, vol. 69, pp. 3325–3333.
21. Zhou, J., Qin, Y., Kou, L., Yuwono, M., SU, S. Fault detection of rolling bearing based on FFT and classification. *J. Adv. Mech. Des. Syst. Manuf.*, 2015, vol. 9.
22. Li, B.; Chow, M.-Y.; Tipsuwan, Y.; Hung, J.C. Neural-Network-Based Motor Rolling Bearing Fault Diagnosis. *IEEE Trans. Ind. Electron.*, 2000, vol. 47, pp. 1060–1069.
23. Haroun, S., Nait Seghir, A., Touati, S. Feature Selection for Enhancement of Bearing Fault Detection and Diagnosis Based on Self-Organizing Map. *Recent Advances in Electrical Engineering and Control Applications. Lecture Notes in Electrical Engineering*. Cham, Switzerland, Springer, 2017, vol. 411.
24. Tandon, N., Choudhury, A. A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings. *Tribol. Int.*, 1999, vol. 32, pp. 469–480.
25. Zandi, O., Poshtan, J. Brushless DC Motor Bearing Fault Detection Using Hall Effect Sensors and a Two-Stage Wavelet Transform. *Proceedings of the 26th Iranian Conference on Electrical Engineering (ICEE2018), Mashhad, Iran, 8–10 May 2018*, pp. 827–833.
26. Liu, Z., Zhang, L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings. *Measurement*, 2020, vol. 149, p. 107002.
27. *Rolling Bearings – Damage and Failures – Terms, Characteristics and Causes*. Geneva, Switzerland, International Organization for Standardization, 2017. ISO 15243:2017 ; publication date: March 2017.
28. Radu, C. *The Most Common Causes of Bearing Failure and the Importance of Bearing Lubrication*. RKB Technical Review, February 2010, pp. 1–7. Available at: <https://www.rkbbearings.com/en/publications.php#sec12> (accessed 23.12.2020).
29. *Bearing Damage and Failure Analysis, SKF Group, PUB BU/13 14219/2 EN*. June 2017, pp. 1–106. Available at: [https://www.skf.com/binaries/pub12/Images/0901d1968064c148-Bearing-failures---14219\\_2-EN\\_tcm\\_12-297619.pdf](https://www.skf.com/binaries/pub12/Images/0901d1968064c148-Bearing-failures---14219_2-EN_tcm_12-297619.pdf) (accessed 23.12.2020).
30. Smith, S. W. *Digital Signal Processing: A Practical Guide for Engineers and Scientists*. Burlington, VT, USA, Elsevier Science, 2002.
31. Lee, C.-Y., Hsieh, Y.-H. Bearing damage detection of BLDC motors based on current envelope analysis. *Meas. Sci. Rev.*, 2012, vol. 12, pp. 290–295.
32. Espinosa, A. G., Rosero, J. A., Cusido, J., Romeral, L., Ortega, J. A. Fault Detection by Means of Hilbert-Huang Transform of the Stator Current in a PMSM With Demagnetization. *IEEE Trans. Energy Convers.*, 2010, vol. 25, pp. 312–318.
33. Bishop, M. C. *Neural Networks for Pattern Recognition*. 1st ed. New York, NY, USA, Oxford University Press, 1996.
34. Haykin, S. *Neural Networks, a Comprehensive Foundation*. New York, NY, USA, Macmillan College Publishing Company, 1994.
35. Yu, H., Wilamowski, B. M. Levenberg-Marquardt Training. *Industrial Electronics Handbook*. 2nd ed. Boca Raton, FL, USA, Intelligent Systems, CRC Press, 2011, Chapter 12, vol. 5, pp. 12–1–12–15.

36. Demuth, H., Beale, M. *Neural Network Toolbox – User's Guide. Version 4*. Natick, MA, USA, The MathWorks, Inc., 2004.
37. Du, Y.-C., Stephanus, A. Levenberg-Marquardt Neural Network Algorithm for Degree of Arteriovenous Fistula Stenosis Classification Using a Dual Optical Photoplethysmography Sensor. *Sensors*, 2018, vol. 18, p. 2322.
38. Zayani, R., Bouallegue, R., Roviras, D. Levenberg-Marquardt learning neural network for adaptive predistortion for time-varying HPA with memory in OFDM systems. *Proceedings of the EUSIPCO2008 – 16th European Signal Processing Conference, Lausanne, Switzerland, 25–29 August 2008*, pp. 1–6. Available at: <https://hal.archives-ouvertes.fr/hal-02457894> (accessed 09.12.2020).
39. Jazayeri, K., Jazayeri, M., Uysal, S. Comparative Analysis of Levenberg-Marquardt and Bayesian Regularization Backpropagation Algorithms in Photovoltaic Power Estimation Using Artificial Neural Network. *Advances in Data Mining. Applications and Theoretical Aspects. ICDM 2016*. Cham, Switzerland, Springer, 2016, vol. 9728.
40. Suliman, A., Omarov, B. S. Applying Bayesian Regularization for Acceleration of Levenberg-Marquardt based Neural Network Training. *Int. J. Interact. Multimed. Artif. Intell.*, 2018, vol. 5, pp. 68–72.
41. Gil, D., Johnsson, M. Supervised SOM Based Architecture versus Multilayer Perceptron and RBF Networks. *Proceedings of the 26th Annual Workshop of the Swedish Artificial Intelligence Society (SAIS), Uppsala, Sweden, 20–21 May 2010*, pp. 15–24.
42. Bayram, S., Ocal, M. E., Laptali Oral, E., Atis, C. D. Comparison of multilayer perceptron (MLP) and radial basis function (RBF) for construction cost estimation: The case of Turkey. *J. Civ. Eng. Manag.*, 2016, vol. 22, pp. 480–490.
43. Fath, A. H., Madanifar, F., Abbasi, M. Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems. *Petroleum*, 2020, vol. 6, pp. 80–91.
44. Jaganathan, B., Venkatesh, S., Bhardwaj, Y., Sridhar, V. Optimal parameters estimation of a BLDC motor by Kohonen's Self Organizing Map Method. *Proceedings of the 2011 IEEE Recent Advances in Intelligent Computational Systems, Trivandrum, Kerala, India, 22–24 September 2011*, pp. 068–071.
45. Jacobs, S., Rios-Gutierrez, F. Self-organizing maps for monitoring parameter deterioration of DC and AC motors. *Proceedings of the 2013 Proceedings of IEEE Southeastcon, Jacksonville, FL, USA, 4–7 April 2013*, pp. 1–6.
46. Khalfaoui, N., Salhi, M. S., Amiri, H. The SOM tool in mechanical fault detection over an electric asynchronous drive. *Proceedings of the 2016 4th International Conference on Control Engineering & Information Technology (CEIT), Hammamet, Tunisia, 16–18 December 2016*, pp. 1–6.
47. Skowron, M., Orłowska-Kowalska, T. Efficiency of cascade-connected neural networks in detecting initial faults to induction motor drive electric windings. *Electronics*, 2020, vol. 9, p. 1314.
48. Dogan, Y., Birant, D., Kut, A. SOM++: Integration of Self-Organizing Map and K-Means++ Algorithms. *Machine Learning and Data Mining in Pattern Recognition. MLDM 2013*. Berlin/Heidelberg, Germany, Springer, 2013, vol. 7988.
49. Bataineh, A. K., Samkari, M. H., Abdualla, A., Al-Azzam, S. K-Means Clustering in WSN with Kohonen SOM and Conscience Function. *Mod. Appl. Sci.*, 2019, vol. 13, pp. 63–75.
50. Ewert, P., Orłowska-Kowalska, T., Jankowska, K. Effectiveness Analysis of PMSM Motor Rolling Bearing Fault Detectors Based on Vibration Analysis and Shallow Neural Networks. *Energies*, 2021, vol. 14, p. 712.