

Обзор методов обнаружения неисправностей синхронного электродвигателя с постоянными магнитами.

Е.А. Саксонов, С.Е. Симонов, М.Г. Городничев

Московский технический университет связи и информатики

Аннотация: Обзор методов существующих неисправностей синхронных электродвигателей и методов их обнаружения. Классификация и анализ существующих методов, их применимость при обнаружении неисправностей, преимущество и недостатки. Рассмотрены и описаны три класса возможных неисправностей синхронного электродвигателя с постоянными магнитами: электрические неисправности, механические неисправности, размагничивание. В статье рассматриваются три класса методов диагностики неисправностей: на основе построения математической модели реального электродвигателя и моделирования его ошибок, на основе обработки сигналов, поступающих с датчиков и интеллектуальные методы на основе обработки собранных данных посредством искусственного интеллекта. Рассмотрены следующие методы обнаружения ошибок на основе моделирования: обнаружение на основе модели электрической принципиальной схемы, на основе аналитической модели, на основе цифровой имитационной модели. Представлены следующие методы частотно-временного анализа получаемых сигналов с датчиков: анализ с использованием быстрого преобразования Фурье, кратковременного преобразования Фурье, Вейвлет-преобразования, преобразования Гильберта-Хуанга, распределения Вигнера-Вилля. Рассмотрены следующие интеллектуальные методы диагностики: диагностика с применением свёрточных нейронных сетей, рекуррентных нейронных сетей, методом опорных векторов, нечеткой логикой и разряженным представлением.

Ключевые слова: синхронный двигатель с постоянными магнитами, неисправности электродвигателя, моделирование, быстрое преобразование Фурье, Вейвлет-преобразование, преобразование Гильберта-Хуанга, распределение Вигнера-Вилля, нейронные сети, нечеткая логика, метод опорных векторов, разряженное представление.

Введение.

В современном мире большая часть энергетических затрат уходит на электродвигатели, среди которых наиболее часто встречаются асинхронные и, в последнее время набирающие популярность, синхронные двигатели с постоянными магнитами (СДПМ) [1].

Синхронный двигатель – это класс синхронных электромашин, к которым также относится генератор и компенсатор. В целом, синхронные электромшины – это аппараты, состоящие из вращающегося и стационарного элемента, которые генерируют, преобразуют, трансформируют или модифицируют электроэнергию. Закон Фарадея об электромагнитной индукции, закон Био-Савара об электромагнитных

индуцированных силах и закон Ленца о действии и противодействии, вместе с законом сохранения энергии составляют основные теоретические части, на которых строится объяснение работы любой электрической машины [2].

СДПМ является электродвигателем переменного тока, в котором в устойчивом состоянии вал вращается синхронно с частотой тока питающей электросети. Период вращения у СДПМ равен целому числу циклов переменного тока.

Все синхронные электродвигатели имеют в своей конструкции статор с многофазными электромагнитами, создающими электромагнитное поле, которое вращается одновременно с колебаниями переменного тока.

Синхронный двигатель имеет схожую конструкцию с асинхронным двигателем.

Статор является неподвижной фиксированной частью синхронного электродвигателя, который состоит из корпуса и сердечника. Сердечник собран из тонких, изолированных друг от друга листов со специальными пазами, в которые помещается обмотка двигателя.

Вторая неотъемлемая часть синхронного электродвигателя – ротор с постоянными магнитами, которые вращаются в такт с полем статора с одной и той же скоростью, в результате чего возникает синхронно вращающееся магнитное поле.

Синхронные двигатели с постоянными магнитами имеют на статоре обмотку, подключенную к источнику переменного тока для создания вращающегося магнитного поля и при синхронной скорости полюса ротора замыкаются на вращающемся магнитном поле. Для запуска и управления СДПМ в большинстве случаев применяют частотный преобразователь.

СДПМ имеют свои характерные конструктивные особенности:

Синхронные двигатели в отличие от асинхронных обладают более высокой энергоэффективностью и имеют лучшее соотношение мощности к

весу и мощности к объему, то есть полезной нагрузкой. При ударных нагрузках в синхронных электродвигателях частота их вращения остается постоянной. Эти отличительные черты позволяют применять синхронные двигатели в металлургической, металлообрабатывающей промышленности, машиностроении, использовать для приведения в действие механизмов обрабатывающих станков, в компрессорных установках, в системах встречной вентиляции и насосного оборудования, но больше всего они применимы в электротранспорте.

По сравнению с асинхронными электродвигателями, СДПМ устойчивы к колебаниям напряжения в питающей сети и при понижении питающего напряжения сохраняют свою перегрузочную способность. Всё это повышает надежность их работы при аварийных событиях в электрической сети.

Тем не менее, как и любые механические устройства, СДПМ подвержены износу и деградации по мере эксплуатации.

Выделяют несколько типов повреждений СДПМ, которые можно разделить на три класса [3]:

1. Электрические неисправности;
2. Механические неисправности;
3. Магнитные неисправности.

Указанные классы неисправностей будут рассмотрены в первой части данной статьи.

Для каждого типа неисправности существует несколько типов её диагностики по Российским и международным стандартам (ГОСТ 11828-86, ПНСТ 168-2016/ISO/DIS 13373-9). Согласно данным стандартам, диагностика производится с помощью вспомогательных приборов: тепловизоров, шумомеров, спектрографов, газоанализаторов и вибродатчиков.

Диагностику можно проводить методом испытаний, но тогда электродвигатель необходимо отключать от технологической линии на плановую диагностику. В этом методе есть существенный недостаток – остановка производства, что влечет за собой экономические потери, но в данном случае происходит полная и качественная диагностика устройства с последующим его обслуживанием. Также возможно диагностировать неисправность косвенными методами в режиме непрерывного мониторинга параметров электродвигателя [4].

К сожалению, не всегда электродвигатели имеют в своей конструкции, например, встроенные вибродатчики и на производстве не всегда есть возможность установить данные датчики. Поэтому часто при диагностике применяют внешние датчики вибрации, которые монтируются на электромашину. В таком случае производят диагностику по паразитным вибрациям. Это пример непрерывного мониторинга, где по изменениям показателей вибрации можно заранее определить, что происходят какие-то аномалии. В данной статье мы будем рассматривать только методы непрерывного мониторинга, обрабатывая показатели датчиков с помощью ЭВМ.

В настоящее время существуют программно-аппаратные комплексы, которые, например, измеряют слабые колебания электромагнитного поля. Благодаря такому подходу можно отследить различные гармоники электромагнитного поля, по которым с помощью косвенных методов и алгоритмов с применением нейронных сетей можно найти и даже предсказать неисправность.

В данной работе для прогнозирования выхода из строя и своевременного обслуживания СДПМ рассматриваются подобные методы предиктивного анализа, позволяющие заранее предсказать тип неисправности и приблизительное время, когда эта неисправность

произойдет. Такой подход позволяет заблаговременно произвести обслуживание необходимы конструктивных частей СДПМ, что значительно повысит срок службы СДПМ и позволит запланировать производственную деятельность предприятия на данном участке.

Существующие методы диагностики будут рассмотрены во второй части данной работы.

В данной работе рассмотрены следующие методы диагностики, которые разделены на три класса (рисунок 1):

1. Методы диагностики на основе моделирования с помощью специализированного программного обеспечения для симуляции работы СДПМ с неисправностями;

2. Метод диагностики частотного диапазона на основе собираемых данных с датчиков, расположенных непосредственно на СДПМ, последующему анализу данных с датчиков и выводу относительно неисправности.

2. Интеллектуальные методы диагностики [5]. Это новейшие методы диагностики, основанные на алгоритмах нейронных сетей. В данных методах используются показания с датчиков, находящихся на СДПМ, на основе которых собирается датасет для анализа с помощью методов искусственного интеллекта

Целью данной работы является рассмотрение существующих методов диагностики электродвигателей, проведение их сравнительного анализа, поиска их достоинств, недостатков и применимости в тех или иных случаях. Результаты проведенного сравнительного анализа будут описаны в заключении данной работы.

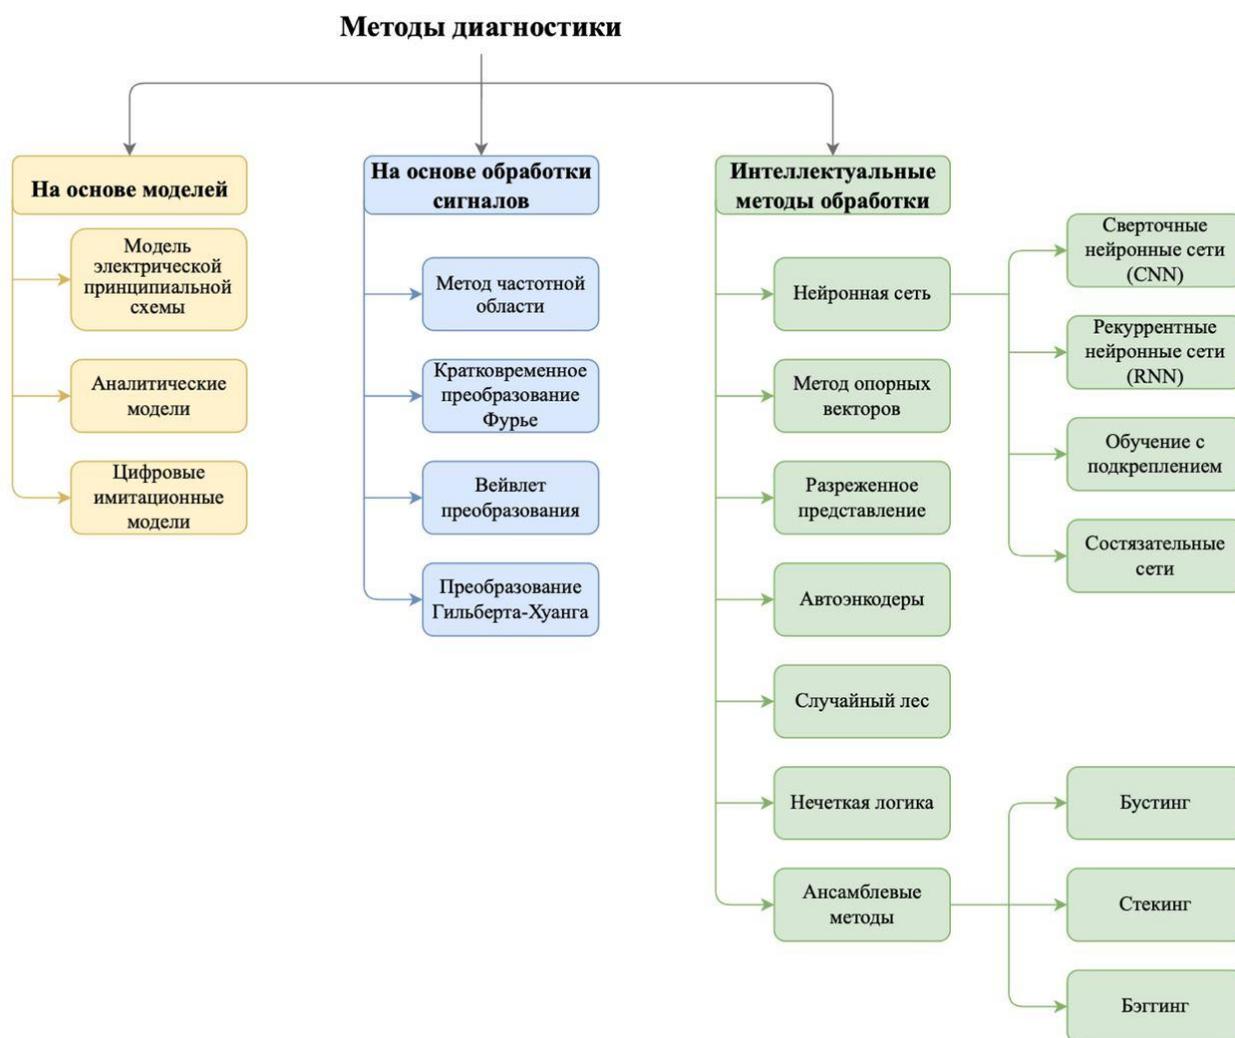


Рис.1. - Существующие методы диагностики электродвигателей

Классификация неисправностей СДПМ.

1. Электрические неисправности.

В основном все электрические неисправности СДПМ возникают при обрыве электрической цепи и при межвитковом коротком замыкании. Обрыв электрической цепи чаще всего происходит по следующим причинам: при некорректной эксплуатации, при несвоевременном обслуживании электродвигателя, из-за перегрева, критического механического воздействия и электромагнитной силы. Размыкание электрической цепи приводит к проблемам с запуском в номинальный режим работы из-за нехватки пусковой мощности.

Очень распространено межвитковое короткое замыкание, которое происходит из-за проблем с изоляцией в обмотке статора: из-за перегрузки электродвигателя повышается температура, что приводит к межвитковому короткому замыканию. Короткое замыкание приводит к увеличению крутящего момента, и как следствие еще больше увеличивает перегрев электродвигателя. Важно обнаружить данную проблему своевременно, так как этот тип неисправности быстро распространяется на большее количество витков обмотки статора, что в итоге может вызвать такую неисправность как размагничивание.

Данный тип неисправности технически можно диагностировать с помощью датчиков температуры и электромагнитного поля.

Когда происходит короткое замыкание в обмотке статора, амплитуда гармоник тока статора увеличивается, а частоты, на которых появляются эти гармоники вычисляются согласно формуле:

$$f = f_s \left(v \frac{Z}{p} \pm 1 \right), \quad (1)$$

Где f_s – частота источника, v – положительное целое число, Z – количество пазов статора, p – количество пар полюсов электродвигателя [3].

2. Механический тип неисправностей.

Механические неисправности возникают в следствии неисправности подшипников из-за ошибок в сборке, плохой смазки подшипников или их перегрузки в процессе эксплуатации. Также бывают отказы и в нормальном режиме эксплуатации, в связи с естественным износом подшипников, что приводит к растрескиванию или расслаиванию подшипников.

Повреждение подшипника приводит к повышенному трению между статором и ротором, что в итоге вызывает нагрев и короткое замыкание.

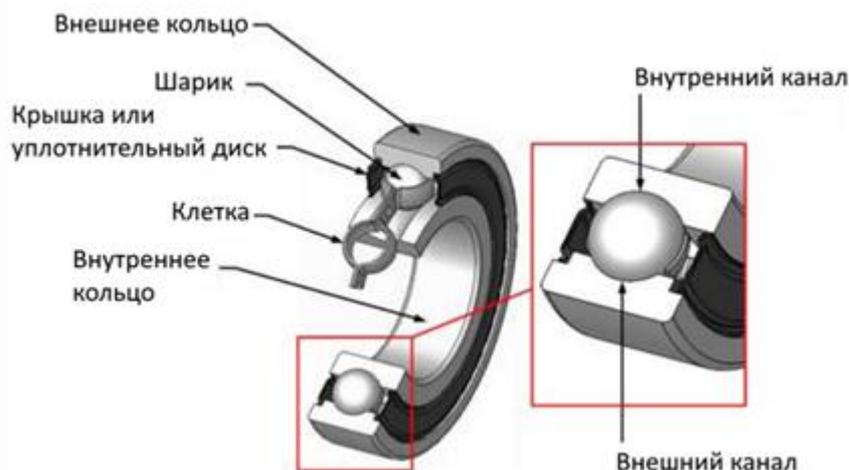


Рис.2 – Внутренняя структура подшипника

Также механические неисправности связаны с эксцентриситетом, т.к. отклонением от идеальной окружности. Данная проблема может возникнуть при монтаже подшипниковых стоек электродвигателя или какой-либо деформации корпусных элементов статора.

3. Размагничивание.

В отличие от асинхронных электродвигателей, у СДПМ конструктивно предусмотрены постоянные магниты, которые при определенных факторах могут быть размагничены. К таким факторам относятся высокая температура, высокие токи статора, которые возникают в результате неисправности обмотки статора, перегрузок. Размагничивание вызывает разность плотности потока и изменяет индуктивность СДПМ. Различные параметры при определении данной неисправности затрудняют обнаружение и диагностику тяжести размагничивания [6, 7]. Существует множество неконтролируемых факторов, например, потеря магнетизма, вызванная механическими дефектами. Степень такого дефекта является случайным процессом. Кроме того, размагничивание является необратимым процессом, поэтому его сложно смоделировать.

Подшипники качения 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 компонентов — 36%, 9% и 14 % соответственно [1].

Методы диагностики на основе моделирования

Методы моделирования можно классифицировать следующим образом:

Аналитические методы – это методы, которые используют математический подход при расчете электрических величин электродвигателя, основываясь на конструкции и геометрии каждого конкретного электродвигателя. При этом некоторые параметры электродвигателя, например, индуктивность можно рассчитать, используя схему обмотки электродвигателя [8].

Методы на основе эквивалентной магнитной цепи (magnetic equivalent circuit - MEC) заключаются в разработке математических выражений эквивалентной магнитной цепи для моделирования электродвигателя. Моделирование плотности потока было дополнительно усовершенствовано за счет улучшенного метода моделирования, известного как метод реконструкции магнитного поля. Данный метод используется для расчета магнитных сил от магнитного поля при произвольном положении ротора [9].

Численные методы. В данных методах параметры, связанные с неисправностью, вычисляются с помощью решений дифференциальных уравнений численными методами. Существуют различные численные методы, например, метод конечных разностей, линейный метод, метод конечных элементов, метод конечного объема и спектральный метод. Метод конечных элементов (finite element method - FEM) считается наиболее точным подходом к моделированию СДПМ. Данный метод может быть применим для выявления различных неисправностей, для оценки электромагнитного поля и потерь в СДПМ.

При моделировании на основе численных методов обычно используются специализированные программы. Такой подход является

достаточно трудоёмким, но с его помощью возможно выполнять анализ с учетом пространственных гармоник и неидеального поведения в электродвигателе. В результате численные методы дают точные результаты, но при этом требуют значительных вычислительных ресурсов.

Методы, основанные на электрической эквивалентной цепи, методы, основанные на магнитной эквивалентной цепи, и подход к моделированию, основанный на численных методах, обсуждались и подробно описывались [10]. Кроме того, было проведено сравнительное исследование данных методов, в котором методы ранжируются по скорости и точности вычислений [11]. Было замечено, что для неисправностей статора СДПМ, например, межвитковое замыкание статора, подход, основанный на электрической эквивалентной цепи, предпочтительнее других методов моделирования. В то время как для неисправностей, связанных с ротором, например, размагничивания, для моделирования неисправности обычно используется метод, основанный на магнитной эквивалентной цепи. Численные методы, такие как FEM, обычно используются для получения более точных результатов и, следовательно, в качестве инструмента проверки результатов, полученных методами моделирования на основе ЕЕС и МЕС [12].

Метод частотно-временного анализа.

Благодаря анализу сигналов с датчиков тока и вибрации методом частотно-временного анализа можно обнаружить характеристики неисправностей и извлекать из них конкретные признаки.

Методы обработки сигналов включают в себя методы временной области, методы частотной области и методы частотно-временного анализа.

Для раннего выявления поломок подшипников используются статистические показатели временного ряда таких параметров как среднее,

пиковое, среднеквадратичное значения, значения эксцесса и т.д. К сожалению, эти показатели недостаточно точны.

1. Быстрое преобразование Фурье (fast Fourier transform - FFT)

К методам диагностики частотной области относится такой метод анализа как быстрое преобразование Фурье (FFT). Быстрое преобразование Фурье отображает измеряемый сигнал в виде суперпозиции нескольких синусоидальных или косинусоидальных функций. FFT метод может чётко отображать частотное распределение сигнала, где амплитуда и частота гармонических составляющих могут быть использованы в качестве характеристик тоё или иной неисправности.

К сожалению, при использовании методов частотной области теряется информация о времени, в этом случае трудно различать похожие гармоники [4, 13].

2. Кратковременное преобразование Фурье (Sparse Fast Fourier Transform - SFFT)

Для того, чтобы сохранилась информация о временной характеристике, был предложен метод частотно-временного анализа. Это улучшенный метод, основанный на FFT, который называется кратковременное преобразование Фурье (SFFT). Данный метод реализует частотно-временной анализ благодаря разделению обрабатываемого сигнала на небольшие временные интервалы с различными типами статистического распределения, такими как прямоугольник, Хэмминг, Гаусс и прочие.

Данный метод хорошо подходит для обработки нелинейного сложного сигнала, но разрешение по времени и частоте зависит от выбранного интервала, который фиксирован, следовательно, разрешение тоже фиксировано на всем частотном и временном диапазоне, и точность разрешения неравномерная. Если же необходимо постоянно высокое разрешение, то данный метод требует высоких вычислительных мощностей,

поэтому не подходит для анализа переходных процессов в электродвигателе [4].

3. Вейвлет-преобразование (Wavelet transform - WT)

Данный метод состоит из дискретного и непрерывного вейвлет-преобразования. Суть метода заключается в том, что входной сигнал подвергается свертке $f(t)$ с помощью материнской вейвлет-функции $\varphi(t)$ и генерации вейвлет-коэффициентов. В вейвлет-функции есть коэффициент масштабирования (a), связанный с частотой и коэффициент свертки (b), связанный с временем, таким образом выражение выглядит следующим образом:

$$W_{\varphi} f(a, b) = \int f(t) |a|^{-\frac{1}{2}} \varphi\left(\frac{t-b}{a}\right) dt \quad (2)$$

В методе WT, в отличие от STFT, параметры a и b могут меняться в зависимости от частоты. Таким образом, благодаря WT, любой сигнал может быть разложен на сигналы в разных частотных диапазонах с разными разрешениями, что позволяет производить точный и гибкий анализ неисправностей СДПМ, таких, как степень размагничивания СДПМ или определение фазы обмотки короткого замыкания [7].

4. Преобразование Гильберта-Хуанга (Hilbert–Huang transform - ННТ)

Данный подход представляет собой метод частотно-временного анализа, который сочетает в себе эмпирическую модовую декомпозицию с преобразованием Гильберта. Первоначально сигнал раскладывается на несколько функций, каждая такая функция представляет собой однокомпонентную функцию, затем с помощью преобразования Гильберта вычисляется мгновенная частота исходного сигнала [14].

Этот метод преодолел недостаток STFT и WT, который заключался в том, что их частотно-временное разрешение было тесно связано с выбором частотного и временного диапазона рассмотрения сигнала. Благодаря этому,

метод ННТ хорошо подходит для динамического анализа сигналов из-за своей чувствительности к переходным частотам, также он показал хорошие результаты в высокоскоростных и динамических условиях эксплуатации.

5. Распределение Вигнера-Вилля (Wigner — Ville transform - WVD).

Основное преимущество данного метода - возможность выявить частотно-временную плотность энергии, которая получается путем корреляции входного сигнала с временем и частотой. Однако, если анализируемый сигнал содержит более одной частотной составляющей, результат WVD будет иметь посторонние шумы, что неблагоприятно для диагностики неисправностей. Для решения этой проблемы, были объединены методы WVD с эмпирической модовой декомпозицией, включенной в ННТ. Его применение следует изучить более подробно, возможно, комбинируя с другими методами [4].

	Преимущества	Недостатки
FFT	+ Точное отображение частотных характеристик	- Не различимы похожие гармоники
SFFT	+ Возможно обрабатывать сложный сигнал	- Требуется высокой вычислительной мощности для анализа переходных процессов
WT	+ Точный и гибкий анализ неисправностей размагничивания и определение фазы обмотки короткого замыкания	- Требуется высокой вычислительной мощности
ННТ	+ Подходит для динамического анализа в высокоскоростных условиях эксплуатации	- Требуется высокой вычислительной мощности
WVD	+ Выявляет частотно-временную плотность энергии	- Если в сигнале существует более одной частотной составляющей, имеет посторонние шумы

Таблица 1. Сравнения методов, основанных на обработке сигналов.

Все рассмотренные методы частотно-временного анализа выявления неисправностей СДПМ могут обеспечивать хорошие результаты в идеальных

условиях, но обладают плохой помехозащищенностью и сильно зависят от параметров двигателя и условий эксплуатации.

Интеллектуальные методы диагностики СДПМ

Алгоритмы искусственного интеллекта и машинного обучения в большинстве своем основаны на обработке собранных предварительных данных, которые размечаются экспертом. Благодаря такому подходу, по входным значениям могут быть автоматически определены тип и степень неисправностей. В последнее время [4] было предложено много различных алгоритмов диагностики, основанных на искусственном интеллекте и машинном обучении. Такие подходы основаны на предварительных данных (датасете) и включают в себя статистические методы, такие, как анализ главных компонент и независимый компонентный анализ. Они используются для определения характеристик при диагностике неисправностей. С интеллектуальными методами диагностики типы неисправностей могут быть определены автоматически с определенной вероятностью по данным, получаемым с датчиков двигателя.

Искусственные нейронные сети (ИНС), широко используемые в областях распознавания образов и аудиоаналитики, возможно применять и в диагностике неисправностей электродвигателей. ИНС должна автоматически определять неисправность и её тип.

Нейронные сети состоят из входного слоя, скрытого слоя и выходного слоя, каждый слой содержит множество узлов. Выходные данные получены из функции активации после вычислений полностью соединенных узлов из нескольких слоев.

Задача ИНС заключается в минимизации ошибки классификации в обучающем наборе данных, а далее похожим образом ИНС должна реагировать на новые входные данные с датчиков электродвигателя.

Например, в работе [15] использовалась третья гармоника СДПМ в качестве входного сигнала в ИНС для распознавания образов, а первая гармоника использовалась для уменьшения ошибки.

Распознавание образов включает в себя обучение с подкреплением и является многомерной инженерной дисциплиной для реализации интеллектуальных машин, которые могут обучаться. Концепция распознавания образов заключается в идентификации или классификации сложных выборок сигналов или объектов, которые имеют между собой общие черты и могут быть связаны друг с другом посредством некоторых определенных характеристик или символов. В этом отношении наиболее важными целями распознавания образов являются моделирование неизвестных классов образов и диагностика образа, принадлежащего известному классу. Распознавание образов состоит из трех этапов: извлечение признаков, выбор признаков и классификация. Этап выделения признаков – это процесс, в котором реализуются различные методы преобразования для извлечения характеризующих признаков необработанного образца, полученных с помощью электронных датчиков. Этап выбора признаков — это процесс, в котором наиболее характерные признаки определяются сразу после этапа выделения признаков. Этап классификации — это процесс, в котором класс шаблона определяется с использованием признаков, выбранных в конце этапа выбора признаков с помощью классификатора.

1. Сверточные нейронные сети (Convolutional Neural Networks - CNN).

Архитектура сверточных нейронных сетей (CNN) основана на использовании сверточных слоев для извлечения признаков из изображений и других типов данных, таких, как временные ряды или звуковые сигналы [16].

Основные компоненты архитектуры сверточной нейронной сети включают в себя:

Сверточный слой (Convolutional layer) - основной блок сверточной нейронной сети. Сверточный слой состоит из нескольких фильтров (ядер), сканирующих входное изображение, выделяя признаки на различных уровнях. Каждый фильтр представляет собой матрицу весов, которые перемещаются по изображению, умножаются на соответствующие пиксели и суммируются, чтобы создать карту признаков.

Слой подвыборки (Pooling layer) - слой, который уменьшает размерность карты признаков, объединяя близлежащие пиксели или признаки в одно значение. Это позволяет снизить количество параметров и сделать модель более устойчивой к небольшим изменениям в данных.

Полносвязный слой (Fully connected layer) - слой, который соединяет выходные данные из предыдущих слоев в один вектор и обрабатывает его, чтобы получить итоговый результат. Этот слой используется для классификации или регрессии на основе извлеченных признаков.

Функция активации (Activation function) - функция, которая применяется к выходу каждого слоя, чтобы добавить нелинейность в модель. Различные функции активации могут быть использованы, включая ReLU, sigmoid, tanh и другие.

Регуляризация (Regularization) - методы, которые помогают снизить переобучение модели, включая Dropout, L1/L2 регуляризацию, аугментацию данных и другие.

В целом, сверточные нейронные сети могут иметь различные архитектуры, включая различное количество сверточных слоев, слоев подвыборки, полносвязных слоев и других компонентов. Эти архитектуры могут быть настроены для конкретных задач, таких, как классификация изображений, диагностика электродвигателей или другие.

Сверточные нейронные сети могут быть эффективным инструментом для диагностики электродвигателей. CNN являются типом глубоких

нейронных сетей, которые способны извлекать признаки из изображений и других типов данных с помощью сверточных слоев.

С целью применения сверточных нейронных сетей для диагностики электродвигателей, необходимо иметь набор данных, содержащий различные состояния двигателя, например, нормальное состояние, перегрев, перегрузка и т.д. Каждый набор данных может быть представлен в виде временных рядов, собранных с датчиков двигателя.

Затем, для обучения сверточной нейронной сети, данные могут быть представлены в виде спектрограмм, которые являются 2D-изображениями, отображающими временной ряд, как функцию времени и частоты. Сверточные слои в нейронной сети позволяют извлекать признаки из спектрограмм, такие, как изменения частоты или амплитуды, которые могут указывать на определенные состояния двигателя.

После обучения нейронной сети на наборе данных, можно использовать ее для диагностики новых состояний двигателя. Входные данные, получаемые от датчиков двигателя, могут быть преобразованы в спектрограммы и поданы на вход нейронной сети, которая выдает предсказание о состоянии двигателя [17].

Преимущества использования сверточных нейронных сетей для диагностики электродвигателей включают способность автоматически извлекать признаки из временных рядов, учет динамических изменений в данных и возможность работы с различными типами датчиков и сигналов.

CNN обычно состоят из сверточных слоев, слоев ReLU, слоев объединения и полностью подключенного слоя. В процессе обучения входные выборки распространяются вперед для изучения характеристик и классификации, а ошибки распространяются обратно, пока модель не будет окончательно завершена.

В работе [18] сначала осуществлялись преобразования выделенных особенностей, извлеченных с помощью методов частотно-временного анализа (описанных выше), в двумерные, а затем для диагностики они анализировались с помощью 2D-CNN.

В работе [19] рассмотрен метод преобразования необработанных сигналов во временной области в двумерное изображение серого цвета, что устранило необходимость в дополнительных этапах извлечения признаков. В данной работе проведено сравнение этого метода с другими.

Недостаток указанного метода заключается в том, что он требует много времени и предъявляет высокие требования к вычислительному оборудованию.

В работе [15] напрямую вводится сигнал во временной области, собранный в двигателе, в 1D-CNN для диагностики неисправности.

В работе [20] провели сравнение методов CNN с WPT и показали, что методы с использованием CNN обладают лучшей точностью.

Метод CNN может извлекать локальные особенности входных данных и комбинировать абстракцию для генерации высокоуровневых объектов слой за слоем, что может эффективно реализовать диагностику неисправностей.

2. Рекуррентные нейронные сети (recurrent neural network - RNN).

Рекуррентная нейронная сеть (RNN) - это класс нейронных сетей, способных обрабатывать последовательности данных, такие, как текст, временные ряды, звуковые сигналы и другие.

В отличие от сверточных нейронных сетей, которые рассматривают каждый элемент входных данных независимо друг от друга, RNN используют внутреннюю память, чтобы сохранять информацию о предыдущих состояниях входных данных. Это позволяет модели запоминать информацию о контексте и последовательности данных.

Основные компоненты архитектуры RNN включают в себя:

Слой рекуррентных нейронов (Recurrent layer) - основной блок RNN. Слой рекуррентных нейронов имеет внутреннее состояние (скрытое состояние), которое сохраняет информацию о предыдущих элементах последовательности данных. Это состояние передается от одного элемента последовательности к другому и используется для обработки каждого нового элемента.

Функция активации (Activation function) - функция, которая применяется к выходу каждого слоя рекуррентных нейронов, чтобы добавить нелинейность в модель. Могут быть использованы различные функции активации, включая tanh, ReLU и другие.

Полносвязный слой (Fully connected layer) - слой, который соединяет выходные данные из последнего слоя рекуррентных нейронов в один вектор и обрабатывает его, чтобы получить итоговый результат. Этот слой используется для классификации или регрессии на основе извлеченных признаков.

Регуляризация (Regularization) - методы, которые помогают снизить переобучение модели, включая Dropout, L1/L2 регуляризацию, аугментацию данных и другие [5].

Рекуррентная нейронная сеть обеспечивает эффективное решение проблемы извлечения информации из изменяющихся во времени сигналов. Это происходит благодаря способности использовать изменяющуюся во времени информацию путем запоминания введенной последовательности. RNN широко используется в обработке естественного языка, генерации текста, распознавания речи. Информация, изменяющаяся во времени, имеет большое значение в анализе сигналов, следовательно, можно использовать RNN для анализа электрических сигналов.

Различие между традиционной нейронной сетью и RNN заключается в том, что в RNN есть цикл, который позволяет модели запоминать

информацию и использовать ее для расчета следующего временного шага. Так в RNN выходные данные последнего момента времени являются входными данными следующего момента, что позволяет информации последовательно передаваться на следующий шаг. В RNN входные сигналы каждого момента сохраняются в процессе рекуррентного вычисления, а также сохраняют информацию об отношении временного порядка.

RNN имеют и ряд своих ограничений. Главный недостаток RNN заключается в сложности обработки длинных последовательностей, в этом случае RNN сложно обучать [20]. Для решения этих проблем разработана кратковременная память (LSTM), которую можно использовать для определения того, следует ли запоминать информацию в каждом цикле. LSTM добавляет процесс оценки в каждом повторяющемся вычислении, чтобы решить следует ли сохранять информацию или нет.

Идея метода диагностики и обнаружения неисправностей в СДПМ заключается в том, что необходимо предсказать значение тока в следующий момент выборки путем обнаружения трехфазного тока и информации о положении ротора в нескольких предыдущих моментах выборки. Таким образом, сравнивая прогнозируемое текущее значение выхода сети и фактическое значение можно выявить ошибку и, если она внезапно увеличивается, то можно подтвердить неисправность двигателя. Кроме этого, обнаружение неисправностей на основе LSTM может значительно уменьшить возмущение внешнего крутящего момента, тем самым снизить частоту промахов и ложных срабатываний [21].

3. Метод опорных векторов (support vector machines - SVM).

Метод опорных векторов (SVM), широко используемая теория машинного обучения, была предложена Вапником в 1999 году [22, 23]. Основная идея SVM заключалась в максимизации расстояния между обучающими данными и границей принятия решения в пространстве

признаков. Граница принятия решения может быть сформирована путем разделения гиперплоскости и обучающих векторов, ближайших к границе принятия решения, которые называются опорными векторами, для определения её положения.

В работе [23] рассмотрены два варианта диагностики СДПМ методом опорных векторов: 1) простая диагностика для определения неисправностей, 2) комплексная диагностика системы для определения места неисправности, реализованная с использованием одноклассовых и двухклассовых SVM соответственно. Оба решения предоставляют надежную диагностическую информацию о неисправностях асинхронных двигателей. В данной работе SVM использовалась только для реализации выбора и классификации текущих характеристик, а извлечение и выражение признаков не реализовано, также была низкая точность диагностики. После обучения скорректированные параметры SVM были исправлены, и система была готова к обнаружению неисправности в режиме онлайн на основе фактической регистрации тока статора. Результаты работы показывают, что метод опорных векторов в сочетании с правильным выбором функций обеспечивает хорошее решение для автоматического обнаружения дефектов вала двигателя. По сравнению с нейронными сетями с обратным распространением, классификаторы SVM имели более высокую точность и меньшее время обучения.

По сравнению с NN, SVM больше подходит для классификации небольших образцов. Однако базовая модель SVM может использоваться только для решения проблемы двух классов.

Кроме того, поскольку производительность SVM в значительной степени зависит от выбора параметров, следует также отметить алгоритмы оптимизации параметров, такие, как particle swarm optimization (PSO) [24].

4. Нечеткая логика (Fuzzy logic)

Нечеткая логика может использоваться для диагностики электродвигателей в ситуациях, когда существует неопределенность или неясность в данных о состоянии двигателя. Например, в случае, когда датчик работает неправильно или данные, получаемые от датчика, не являются четкими или точными, в ситуации, когда измерительные данные подвержены зашумлению.

Для диагностики электродвигателей с помощью нечеткой логики, необходимо определить нечеткие множества, которые описывают различные состояния двигателя. Например, множество "нормальное состояние" может иметь степень принадлежности от 0 до 1 в зависимости от того, насколько близки данные о состоянии двигателя к нормальным значениям. Аналогично, можно определить нечеткие множества для состояний "перегрев", "перегрузка", "короткое замыкание" и т.д.

Затем необходимо определить нечеткие правила, которые связывают состояния двигателя с диагностическими результатами. Например, правило "Если температура двигателя выше определенного уровня, то это указывает на состояние перегрева" может быть представлено в виде нечеткого правила с уровнем достоверности от 0 до 1.

Кроме того, необходимо определить методы агрегации нечетких результатов, например, методы суммирования или взвешивания, чтобы получить итоговый диагностический результат.

Преимущества использования нечеткой логики для диагностики электродвигателей включают возможность учета неопределенности в данных и более точную диагностику в условиях, когда данные не являются точными или четкими.

Преимущество нечёткой логики заключается в том, что закон между признаками неисправности и самими неисправностями может быть получен

без сбора и обработки больших объемов данных. При этом достаточно сложно определять неисправность и её тип вначале её появления [25].

Нечеткая логика обладает хорошей гибкостью и устойчивостью к неточным данным, но на результаты влияют нечеткие правила и нечеткие множества. В дополнение к этим общим основным диагностическим методам необходимо использовать комбинацию нескольких диагностических методов в совокупности, например, как представлено в работе [26].

5. Разреженное представление.

Разреженное представление (Sparse Representation - SR) - это метод представления данных, в котором большинство элементов содержат нулевые значения. Такой подход используется для эффективного хранения и обработки больших объемов данных, для которых большинство значений равно нулю или близко к нулю.

В разреженном представлении данные хранятся в виде пар "индекс-значение". Индекс указывает на позицию элемента в массиве или матрице, а значение содержит само значение элемента. В случае, когда большинство элементов содержат нулевые значения, такой подход позволяет существенно сократить количество используемой памяти и ускорить операции над данными.

Разреженное представление широко используется в таких областях, как компьютерное зрение, обработка естественного языка, машинное обучение, обработка сигналов и других областях, где необходимо эффективное хранение и обработка больших объемов данных.

Разреженное представление может быть использовано для диагностики электродвигателей, чтобы определить неисправности и повреждения, такие как износ подшипников, короткое замыкание в обмотках, и другие типы неисправностей. Это достигается путем анализа электрических сигналов, генерируемых двигателем, и представления их в разреженном формате.

Для диагностики электродвигателей с помощью разреженного представления, входные данные, такие как ток и напряжение собираются во время работы двигателя и сохраняются в виде временных рядов. Затем эти временные ряды преобразуются в разреженные представления, используя алгоритмы сжатия данных, такие, как метод главных компонент (PCA) или алгоритмы редукции размерности, такие, как t-SNE.

Полученные разреженные представления могут быть использованы для поиска неисправностей и повреждений в электродвигателе. Например, изменения в разреженном представлении могут указывать на появление новых неисправностей или изменение параметров работы двигателя [27].

В области диагностики неисправностей электродвигателей, разреженное представление использовалось для подавления шума сигнала, выделения признаков и классификации неисправностей. В работе [28] использовался алгоритм поиска соответствия (MP) для получения наибольших N -разреженных коэффициентов для СДПМ с различными неисправностями и в работе [29] они рассмотрены, как особенности. Основываясь на этом, использовался алгоритм поиска ортогонального соответствия (OMP) и отправлялись векторы признаков в SVM. Что касается классификации, SRC не так точен, как SVM, хотя и быстрее. Таким образом, совместная модель для диагностики неисправностей подшипников, которая объединила SRC с SVM, была предложена в работе [29].

Заключение

В данной работе была собрана информация о возникающих ошибках в синхронных электродвигателях с постоянными магнитами и методах их диагностики. Существующие методы диагностики были разделены на три класса, каждый из которых имеет свои преимущества и недостатки, они сведены в единую таблицу 2.

При анализе было замечено, что чаще всего авторы рассмотренных статей применяют комбинированные методы выявления разных видов ошибок. В основном рассматривается комбинация методов, основанных на обработке сигналов и в дальнейшем, промежуточные результаты анализируются интеллектуальными методами. Большинство методов диагностики неисправностей используют нейронные сети, вейвлеты и методы, основанные на обработке сигналах в целом. Данный подход снижает требуемые вычислительные ресурсы, однако эти методы не очень устойчивы к помехам и неизвестным входным сигналам, и, таким образом, изменения скорости и нагрузки электродвигателя могут влиять на диагностику неисправности, приводя к неправильному расположению неисправности или идентификации этой неисправности.

Методы, основанные на обработке данных, с использованием искусственного интеллекта потребляют много вычислительных ресурсов и требуют собранного сбалансированного датасета, при этом данные для этого датасета должны быть собраны в различных условиях эксплуатации и окружающей среды для повышения точности обнаружения, классификации и прогнозирования ошибок.

Предлагается продолжить разрабатывать комбинационные методы, только основанные на математических моделях с генерацией различных условий эксплуатации и окружающей среды электродвигателя, а также на основе сгенерированных интеллектуальными методами данных для создания модели с целью обнаружения ошибок. И сравнить полученные результаты моделирования с данными, полученными с реального испытательного стенда.

Ниже представлена сравнительная таблица 2 преимуществ и недостатков всех рассмотренных в данной статье методов диагностики синхронных электродвигателей с постоянными магнитами.

Класс методов диагностики	
Преимущества	Недостатки
На основе моделей	
Может быть естественным образом интегрирован в отказоустойчивую схему управления.	Они требуют хорошо откалиброванных моделей.
Может быть высокоточным.	Физика реальных систем часто слишком случайна и сложна для моделирования.
Требует меньше данных, чем методы, основанные на данных.	Время выборки (или частота выборки) играет важную роль
Все этапы диагностики могут быть задуманы с использованием одной и той же модели.	
На основе обрабатываемых сигналов	
Не требуют какой-либо модели, основанной на физике двигателя	Риск ложных срабатываний из-за помех и изменений в рабочих условиях
	Высокоскоростные вычислительные мощности для преобразования сигналов в реальном времени.
Историческая информация о двигателе не требуется.	Точность диагностики зависит от качества датчиков, которые обеспечивают сигналы.
	Время выборки важно
На основе обработки данных	
Не требуют какой-либо модели, основанной на физике двигателя	Точность диагностики зависит от количества и качества данных.
Подходят для приложений, где модель недоступна.	Требуются исторические данные о поведении на протяжении всего активного срока службы двигателя.
Подходят для процессов со многими измеряемыми переменными	Требуется значительное количество датчиков для сбора данных
Время выборки не важны.	

Таблица 2. Сравнение рассматриваемых методов диагностики

Литература (References)

1. Baker, D., Baskin, J., Goble, S., Irvine, R.G., Moylan, W., Schlake, R.. Application and Coordination of Protective Devices. IEEE Recommended Practice for Electric Power Distribution for Industrial Plants, Dec. 2, 1993, Piscataway, USA, pp. 227-230. DOI: 10.1109/ieeestd.1994.121642.
 2. Guo, S., Li, X., & Li, Y. A new method for nonlinear system identification based on adaptive wavelet neural network. Simulation Modelling Practice and Theory, 18, 2010, France, DOI: 10.1016/j.simpat.2010.05.019.
 3. Wang, Z.; Yang, J.; Huiping, Yu.; Zhou, U. Review of fault diagnosis of a synchronous motor with permanent magnets. In Proceedings of the IEEE Conference and the Exhibition of Transport Electrification in the Asia-Pacific Region (ITEC Asia-Pacific), Beijing, China, August 31–September 3, 2014, pp. 1-5. DOI: 10.1109/ITEC-AP.2014.6940870.
 4. Chen, Y., Liang, S., Li, W., Liang, H., & Wang, C.. Faults and Diagnosis Methods of Permanent Magnet Synchronous Motors: A Review. Applied Sciences, 9(10), 2019. doi:10.3390/app9102116.
 5. Xu, X., Qiao, X., Zhang, N., Feng, J., & Wang, X. Review of Intelligent Fault Diagnosis for Permanent Magnet Synchronous Motors in Electric Vehicles. Advances in Mechanical Engineering, vol. 12, no. 7, 2020, article 168781402094432. DOI: 10.1177/1687814020944323.
 6. Kang, G.-H.; Hur, J.; Nam, H.; Hong, J.-P.; Kim, G.-T. Analysis of irreversible magnet demagnetization in line-start motors based on the finite-element method. IEEE Transactions on Magnetics, vol. 39, no. 3, 2003, pp. 1488-1491. DOI: 10.1109/TMAG.2003.810330.
 7. Gritli, Y.; Rossi, C.; Casadei, C.; Casadel, D.; Zarri, L. Demagnetizations diagnosis for permanent magnet synchronous motors based on advanced wavelet analysis. IEEE Transactions on Electrical Machines, vol. 58, no. 10, 2012, pp. 2397-2403. DOI: 10.1109/ICEIMach.2012.6350219.
-

8. Lo, H.; Lo, Y.; Tolyat, H.A.; El-Antabi, A.; Lipo, T.A. Modeling of asynchronous machines with multiple connected circuits. *IEEE Transactions on Industry Applications*, vol. 31, no. 2, 1995, pp. 311-318. DOI: 10.1109/TIE.2003.812471.

9. Li, Y.; Liang, Y. A comparative study on inter-tern short circuit fault of PMSM using finite element analysis and experiment. In *Proceedings of the 2015 International Conference on Advanced Mechatronic Systems*, Beijing, China, 22–24 August 2015; pp. 290–294. DOI: 10.1109/ICAMechS.2015.7287076.

10. Fitouri, M.; BenSalem, Y.; Abdelkrim, M.N. Analysis and co-simulation of permanent magnet synchronous motor with short-circuit fault by finite element method. In *Proceedings of the 13th International Multi-Conference on Systems, Signals & Devices (SSD)*, Leipzig, Germany, March 31 - April 3, 2016, pp. 472-477. DOI: 10.1109/SSD.2016.7473721.

11. Nedjar, B.; Vido, L.; Hlioui, S.; Amara, Y.; Gabsi, M. Hybrid coupling: Magnetic equivalent circuit coupled to finite element analysis for PMSM electromagnetic modeling. In *Proceedings of the IEEE International Symposium on Industrial Electronics*, Hangzhou, China, May 28-31, 2012, pp. 858-862. DOI: 10.1109/ISIE.2012.6237201.

12. He, J.; Somogyi, C.; Strandt, A.; Demerdash, N.A.O. Diagnosis of stator winding short-circuit faults in an interior permanent magnet synchronous machine. In *Proceedings of the 2014 IEEE Energy Conversion Congress and Exposition (ECCE)*, Pittsburgh, PA, USA, 14-18 September 2014; pp. 3125-3130. DOI: 10.1109/ECCE.2014.6953825.

13. Cira, F.; Arkan, M.; Gumus, B. A new approach to detect stator fault in permanent magnet synchronous motors. In *Proceedings of the IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, Guarda, Portugal, 1–4 September 2015; pp. 316–321. DOI: 10.1109/DEMPED.2015.7303708.

14. Faiz, J.; Ghorbanian, V.; Ebrahimi, B.M. A new criterion for rotor broken bar fault diagnosis in line-start and inverter-fed induction motors using Hilbert-Huang transform. In Proceedings of the 2012 IEEE International Conference on Power Electronics, Drives and Energy Systems, Bengaluru, India, 16–19 December 2012; pp. 1–6. DOI: 10.1109/PEDES.2012.6484397.

15. Ince, T.; Kiranyaz, S.; Eren, L.; Askar, M.; Gabbouj, M. Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks. IEEE Transactions on Industrial Electronics, vol. 63, no. 11, pp. 7067-7075, 2016. DOI: 10.1109/TIE.2016.2582729.

16. Cong, S.; Zhou, Y. A review of convolutional neural network architectures and their optimizations. Artificial Intelligence Review, vol. 56, no. 3, 2023, pp. 1905-1969. DOI: 10.1007/s10462-022-10213-5.

17. Albelw S., Mahmood A. A Framework for Designing the Architectures of Deep Convolutional Neural Networks. Entropy. №19(6). 2017. doi.org/10.3390/e19060242

18. Lu, C.; Wang, Y.; Ragulskis, M.; Cheng, Y. Fault Diagnosis for Rotating Machinery: A Method based on Image Processing. PLoS ONE, vol. 11, no. 10, 2016. DOI: 10.1371/journal.pone.0164111.

19. Wen, L.; Li, X.; Gao, L.; Zhang, Y. A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method. IEEE Transactions on Industrial Electronics, vol. 65, no. 7, 2018, pp. 5990-5998. DOI: 10.1109/TIE.2017.2774777.

20. Kao, I.; Wang, W.; Lai, Y.; Perng, J. Analysis of Permanent Magnet Synchronous Motor Fault Diagnosis Based on Learning. IEEE Transactions on Instrumentation and Measurement, vol. 68, no. 1, 2019, pp. 310-324. DOI: 10.1109/TIM.2018.2847800.

21. Pati, Y.C.; Rezaifar, R.; Krishnaprasad, P.S. Orthogonal Matching Pursuit: Recursive Function Approximation with Applications to Wavelet Decomposition. In Proceedings of the 27th Asilomar Conference on Signals, Systems and

Computers, Pacific Grove, CA, USA, November 1-3, 1993, pp. 40-44. DOI: 10.1109/ACSSC.1993.342465.

22. Liang, S.; Chen, Y.; Liang, H.; Li, X. Sparse Representation and SVM Diagnosis Method Inter-Turn Short-Circuit Fault in PMSM. *Applied Sciences*, vol. 9, no. 2, 2019, p. 224. DOI: 10.3390/app9020224.

23. Zhong, J.; Yang, Z.; Wong, S.F. Machine condition monitoring and fault diagnosis based on support vector machine. In *Proceedings of the IEEE International Conference on Industrial Engineering and Engineering Management*, Macao, China, October 7-10, 2010, pp. 2228-2233. DOI: 10.1109/IEEM.2010.5674594.

24. Kurek J, Osowski S. Support vector machine for fault diagnosis of the broken rotor bars of squirrel-cage induction motor. *Neural Computing and Applications*, vol. 19, pp. 557-564, 2010. DOI: 10.1007/s00521-009-0316-5.

25. Li, X., Palazzolo, A., Wang, Z. Rotating Machinery Monitoring and Fault Diagnosis With Neural Network Enhanced Fuzzy Logic Expert System. *Proceedings of the ASME Turbo Expo 2016: Turbomachinery Technical Conference and Exposition*, Seoul, South Korea, June 13-17, 2016. DOI: 10.1115/GT2016-58102.

26. Burriel, J., Puche, R., Martinez, J., et al. Automatic Fault Diagnostic System for Induction Motors Under Transient Regime Optimized with Expert Systems. *Electronics*, vol. 8, no. 1, 2019, article 6, Valencia, Spain. DOI: 10.3390/electronics8010006.

27. Zhang, Z., Xu, Y., Yang, J., Li, X., Zhang, D. (2015). A Survey of Sparse Representation: Algorithms and Applications. *IEEE Access*, vol. 3, 2015, pp. 490-530. DOI: 10.1109/access.2015.2430359.

28. Hou, J., Wang, Y., Gao, T., Yang, Y. Fault Feature Extraction of Power Electronic Circuits Based on Sparse Decomposition. *Proceedings of the 2016*



International Conference on Condition Monitoring and Diagnosis (CMD), 2016, DOI: 10.1109/CMD.2016.7757872.

29. Hassani, H., Zarei, J., Arefi, M.M., & Razavi-Far, R. (2017). zSlices-Based General Type-2 Fuzzy Fusion of Support Vector Machines With Application to Bearing Fault Detection. IEEE Transactions on Industrial Electronics, vol. 64, no. 9, 2017, pp. 7210-7217. DOI: 10.1109/TIE.2017.2688963.