

Диагностика неисправностей подшипников асинхронных двигателей на основе разложения тока статора по сингулярным значениям

Ю.Л. ЖУКОВСКИЙ¹ ✉, А.Д. БУЛДЫСКО¹, И.Е. РЕВИН²

¹ Санкт-Петербургский горный университет, Санкт-Петербург, Россия

² Национальный центр когнитивных разработок, университет ИТМО, Санкт-Петербург, Россия

✉ zhukovskiy_yul@pers.spmi.ru

Ссылка для цитирования оригинальной статьи: Zhukovskiy, Y.; Buldysko, A.; Revin, I. Induction Motor Bearing Fault Diagnosis Based on Singular Value Decomposition of the Stator Current. *Energies* 2023, 16, 3303. <https://doi.org/10.3390/en16083303>

Аннотация: К числу наиболее распространенных систем на промышленных предприятиях относятся автоматизированные приводные системы, ключевым и наиболее распространенным элементом которых является асинхронный двигатель. Ввиду сложных условий эксплуатации оборудования актуальной является задача обнаружения неисправностей на основе анализа электрических параметров. Авторы предлагают выявлять закономерности, характеризующие возникновение и развитие дефекта подшипника, методом сингулярного анализа применительно к сигнатуре тока статора. В результате декомпозиции временные ряды трехфазного тока представляются сингулярными тройками, упорядоченными по убыванию вклада, которые реконструируются в виде временных рядов для последующего анализа с помощью ханкелизации матриц. Экспериментальные исследования с имитацией повреждений подшипников позволили установить связь между изменением вклада реконструированного временного ряда и наличием различных уровней дефектов подшипников. Используя уровень вклада и отслеживая движение конкретного временного ряда, стало возможным наблюдать как появление новых компонентов в текущем сигнале, так и изменение вклада компонентов, соответствующих дефекту, в общую структуру. Авторы проверили результаты кластеризации на основе визуальной оценки сходства структуры матриц компонентов с помощью скаттерграмм и иерархической кластеризации. Реконструкция временного ряда по результатам группировки компонентов позволяет использовать эти компоненты для последующего прогнозирования развития неисправностей в электродвигателях.

Ключевые слова: асинхронный двигатель; надежность; обнаружение неисправностей; анализ временных рядов; сингулярный спектральный анализ; ССА; сингулярное разложение; РСЗ; цифровые технологии; машинное обучение.

Induction Motor Bearing Fault Diagnosis Based on Singular Value Decomposition of the Stator Current

Yuriy L. ZHUKOVSKIY¹ ✉, Aleksandra D. BULDYSKO¹ and Ilia E. REVIN²

¹ Saint Petersburg Mining University, Saint Petersburg, Russia

² National Center for Cognitive Research, ITMO University, Saint Petersburg, Russia

✉ zhukovskiy_yul@pers.spmi.ru

Abstract: Among the most widespread systems in industrial plants are automated drive systems, the key and most common element of which is the induction motor. In view of challenging operating conditions of equipment, the task of fault detection based on the analysis of electrical parameters is relevant. The authors propose the identification of patterns characterizing the occurrence and development of the bearing defect by the singular analysis method as applied to the stator current signature. As a result of the decomposition, the time series of the three-phase current are represented by singular triples ordered by decreasing contribution, which are reconstructed into the form of time series for subsequent analysis using a Hankelization of matrices. Experimental studies with bearing damage imitation made it possible to establish the relationship between the changes in the contribution of the reconstructed time series and the presence of different levels of bearing defects. By using the contribution level and tracking the movement of the specific time series, it became possible to observe both the appearance of new components in the current signal and the changes in the contribution of the components corresponding to the defect to the overall structure. The authors verified the clustering results based on a visual assessment of the component matrices' structure similarity using scattergrams and hierarchical clustering. The reconstruction of the time series from the results of the component grouping allows the use of these components for the subsequent prediction of faults development in electric motors.

Keywords: digital technologies; induction motor; reliability; fault detection; time series analysis; singular spectrum analysis; SSA; singular decomposition; SVD; machine learning.

* Перевод подготовлен для повышения интереса русскоязычной аудитории к данной статье.

1. Введение

Новая эра интеллектуального производства характеризуется развитием как промышленных технологий, так и информационных систем. Кроме того, компоненты промышленных систем становятся все более сложными и в то же время «подключенными». Любая техническая система, даже самая надежная, требует обслуживания и ремонта. Сложность и разнообразие оборудования, используемого в нефтегазовой отрасли, обуславливает необходимость присутствия широкого круга специалистов. Выход из строя даже одного элемента производственной системы приведет к увеличению времени простоя, которое растет пропорционально удаленности предприятия и сложности логистики, что особенно актуально по мере продвижения нефтегазодобычи во все более труднодоступные регионы.

Надежность и доступность – лучшие показатели для количественной оценки долговечности и отказоустойчивости оборудования. Надежность определяется как вероятность безотказного выполнения рабочей задачи в течение определенного периода времени [1, 2]. Доступность означает вероятность того, что оборудование будет находиться в рабочем состоянии в течение запланированного рабочего времени [3]. Эффективность работы, зависящая от производительности оборудования, оказывает непосредственное влияние на конкурентоспособность любой производственной компании [4-6].

Согласно исследованиям Международного энергетического агентства, электродвигатели потребляют более 40 % электроэнергии в мире [7-9] и производят около 5 Гт выбросов CO₂ [10].

Кроме того, даже небольшое повышение эффективности электродвигателей может значительно снизить энергопотребление и выбросы. Экономический потенциал повышения энергоэффективности электромеханических систем с нерегулируемыми приводами составляет около 20-30 %, что позволит снизить общий спрос на электроэнергию на 10 % [11].

На системы электропривода приходится более 60 % общего потребления электроэнергии в нефтегазовой отрасли. В регулируемых и нерегулируемых приводах в настоящее время в основном используются асинхронные двигатели с короткозамкнутым ротором. Электропривод на основе асинхронного двигателя (АД) считается основным на объектах нефтедобычи. Любой отказ в системе привода приводит к значительным экономическим потерям, а наличие развивающихся дефектов в асинхронном двигателе – к снижению его энергоэффективности и дополнительным потерям энергии. Учитывая длительную эксплуатацию электрических машин в нефтегазовой отрасли и срок службы более 15-20 лет, появление дефекта приводит к увеличению экономических потерь и ухудшению экологических показателей предприятия [12, 13].

Для создания надежной и эффективной модели жизненного цикла оборудования необходимо иметь инструменты, которые помогут определить момент времени, когда оборудование необходимо заменить на основе заранее составленного плана использования. Это позволит наметить фазу снижения стоимости владения и повышения эксплуатационных расходов [14, 15].

Стратегия технического обслуживания и соответствующее статистическое распределение должны быть основаны на частоте возникновения отказов и поломок системы. Исследователи сделали большую работу в области создания таких инструментов: были предложены методы оптимизации транспорта [16, 17]; рассмотрены преимущества и применение ИНС для прогнозирования в различных операциях [18-25]; также ведутся исследования по разработке интеллектуальной оптимальной стратегии управления энергией [26-34]. Весьма актуальна тема повышения надежности и готовности оборудования за счет использования различных интеллектуальных компьютерных систем [35-37]; от выбранного подхода напрямую зависит стратегия планирования и обслуживания, продолжительность жизненного цикла оборудования и, впоследствии, всего предприятия.

Сегодня, в условиях цифровой трансформации промышленности, предприятия, в том числе нефтегазовые компании, оснащаются системами, позволяющими в автоматическом режиме собирать и анализировать параметры технологических процессов, оборудования и систем энергоснабжения. Однако отсутствие моделей для выявления неисправностей и оценки энергозатрат, связанных с уровнем технического состояния, не позволяет в полной мере использовать собранные данные [38-40]. Основными целями использования таких данных сегодня являются оценка деградации характеристик, построение индекса производительности и прогнозирование оставшегося срока службы оборудования [41-44]. Однако в промышленности и научных кругах наметилась тенденция к разработке эффективных методов раннего обнаружения отказов оборудования, разложения факторов, влияющих на техническое состояние, и определения потерь энергии, связанных с техническим состоянием [45-49].

Перспективным является поиск новых методов обнаружения неисправностей с использованием доступных данных от анализаторов качества электроэнергии, счетчиков электроэнергии, устройств Интернета вещей, интеллектуальных датчиков и других появляющихся источников информации в интеллектуальных энергосистемах [50-52]. На основе предложенных подходов к анализу данных электрических параметров можно выполнить декомпозицию сигнала и предоставить пользователям достоверную информацию для алгоритмов оценки энергоресурса, токовых потерь, сравнения режимов нагрузки или технологического процесса и, в дальнейшем, при интеграции информации с другими источниками, выявить причины произошедших отказов оборудования. Основной вклад данной работы по сравнению с последними публикациями по данной теме исследований заключается в том, что мы предлагаем сравнительную оценку различных способов сочетания компонентов в режимах повреждения, уделяя при этом особое внимание ранним изменениям режимов, связанным с начальной стадией деградации подшипника.

Чтобы повлиять на надежность и доступность оборудования для дальнейшего планирования стратегии технического обслуживания и ремонта, мы предлагаем свой инструмент для раннего обнаружения отказа двигателя. Мы убедились в том, что этот метод эффективен для обнаружения раковин в подшипниках; он также экономичен и не требует дополнительного оборудования.

Список используемых аббревиатур представлен в разделе «Сокращения». Остальная часть данной работы построена следующим образом:

- В разделе 2 представлены причины, по которым предиктивная диагностика важна для электродвигателей и промышленности. Также представлен обзор существующих методов диагностики на основе электротехники и их недостатков. Приведены начальные сведения о рассматриваемом методе РСЗ, а также о его применимости в аналогичных задачах.
- В разделе 3 описана экспериментальная методика.
- В следующем разделе представлена общая информация об используемой методике, а также пошагово описан алгоритм сингулярного спектрального анализа (ССА).
- В разделе 5 представлены и обсуждены полученные результаты. Для проверки результатов приводится сравнение с другими методами группировки компонентов.
- В заключительном разделе представлены выводы и перспективы дальнейших исследований.

2. Материалы и методы

Несмотря на высокие темпы развития интеллектуальных систем, алгоритмы обнаружения неисправностей и повышенного энергопотребления электрических машин часто сталкиваются с рядом ограничений, таких как отсутствие доступа к историческим данным [53] или к качественному определению наличия и, тем более, типа дефекта. Разработка модели надежности для систем электропривода требует наличия хорошо документированной базы данных об отказах двигателей, на которой можно основывать прогнозы отказов или численные модели оборудования [54]. Поэтому большое количество исследований направлено именно на изучение этой области [48, 55-59]. Старение энергетической инфраструктуры – глобальная проблема, поэтому научный поиск и активные действия по совершенствованию технологий, способных повлиять на темпы износа и снизить эксплуатационные расходы, дадут значительный толчок не только нефтегазовой отрасли, но и всем секторам промышленности [60-62].

Интеллектуальные методы позволяют раньше обнаруживать неисправности и впоследствии устранять как сам дефект, так и, возможно, источник проблемы, тем самым продлевая жизненный цикл систем электропривода, повышая энергоэффективность и снижая воздействие на окружающую среду. Начиная с самого важного элемента приводной системы – производственной базы – будет осуществлен переход к предиктивному обслуживанию и «цифровому предприятию», однако для этого необходимо полностью реформировать систему поддержки принятия решений (СППР) для технического обслуживания и ремонта оборудования (ТОиР) [11].

Среди работ, анализирующих отказы АД, более 40 % [63] неисправностей электрических машин вызваны поломкой подшипников. Это явление объясняется высокими скоростями (оборотами) и суровыми условиями, в которых может использоваться электродвигатель. Наиболее распространенными причинами выхода из строя подшипников качения являются растрескивание поверхности дорожек качения, неправильный монтаж, ошибки в эксплуатации и коррозия [64]. Подшипник АД обеспечивает поддержку вращающегося вала, расположенного на обоих концах ротора. Этот тип

повреждения характеризуется повышенной скоростью роста, что приводит к быстрому разрушению механических и связанных с ними деталей двигателя. При разрушении подшипника увеличивается трение вала, что вызывает дальнейшее повышение температуры в подшипниках и увеличение потерь энергии. Повреждения также могут быть вызваны радиальным зазором, который первоначально проявляется в виде локализованного питтинга на подшипнике [65]. Это может происходить на внутренней дорожке качения, внешней дорожке качения, сепараторе или поверхности шарика [66]. Эксплуатация электропривода с таким дефектом не приводит к его немедленному выходу из строя, но снижает надежность, долговечность и энергоэффективность работы и экологические показатели всего технологического процесса. Этим также объясняется исследовательский интерес к анализу данных системы электропривода для выявления такого рода дефектов. В настоящее время при изучении поведения сложных систем и в экспериментальных исследованиях широко используется подход, основанный на анализе сигналов, генерируемых системой. Это актуально в тех случаях, когда математическое описание изучаемого процесса невозможно, но в наборе имеются некоторые характерные наблюдаемые величины. В случае идентификации дефектов перед нами стоит задача выделения из сигнала компонента, ответственного за некоторое искажение исходного сигнала (исправного двигателя). Обычно такие «подсигналы» незначительны, особенно на ранних стадиях развития дефекта, что создает дополнительные трудности при их выделении. Поэтому в большинстве случаев обнаружение неисправностей подшипников осуществляется следующим образом: выделение сигнала неисправности, усиление сигнала и идентификация неисправности [67].

Однако мы не беремся утверждать, что данный подход будет применим и к другим типам дефектов, таким как эксцентриситет или несоосность ротора, хотя, как и износ подшипников, эти типы дефектов приводят к более высоким уровням вибрации и энергопотребления.

Для формирования комплексного подхода к идентификации различных видов дефектов необходимо перейти к обобщенной задаче исследования и декомпозиции временных рядов [68, 69].

Среди методов исследования динамики процессов, содержащих сложную переменную структуру, в значительной степени зарекомендовал себя метод, основанный на сингулярном разложении исходной выборки (разложение по сингулярным значениям, РСЗ) [70]. Этот подход достаточно широко используется в задачах определения периодических зависимостей в наблюдаемых временных рядах, фильтрации шумов и сглаживания временных рядов, так как использование сингулярного (спектрального) разложения матрицы позволяет выделить наиболее значимые компоненты ряда и отсеять случайные возмущения.

В последние годы РСЗ находит применение во многих отраслях промышленности, а также широко используется при анализе сигналов механических систем. Например, в статье [67] описывается метод диагностики неисправностей подшипников, сочетающий разложение по сингулярным значениям (РСЗ) и квадратичную огибающую спектра (КОС) для определения типа неисправности тяговой системы скоростного автомобиля; в [71] рассматривается РСЗ с измененным размером матрицы для анализа вибрационных сигналов; авторам удается обнаружить неисправности несоосности. В [72] авторы предлагают новый алгоритм извлечения признаков под названием амплитудный фильтр с разложением по сингулярным значениям (РСЗ-АФ) и подтверждают обнаружение дефектов несоосности и трения ротора. В [73] рассматривается сравнение подходов РСЗ и вейвлет-преобразования с точки зрения базиса векторного пространства. Внимание исследователей также привлекают комбинированные методы; например, в [74] авторы использовали РСЗ для локализации частоты неисправности, а затем оценили ее с помощью фильтра Калмана. В [75] авторы предложили метод РСЗ на основе краткосрочных матричных рядов КСМР с использованием отношения сингулярных значений (SVR), и было показано, что он обладает положительными возможностями локальной идентификации при диагностике неисправностей подшипников качения.

Однако все эти методы, как и большинство других (эмпирическая модовая декомпозиция (ЭМД), вариационная модовая декомпозиция (РВР), ансамблевая эмпирическая модовая декомпозиция (АЭМД), вейвлет-преобразование и т. д.), направлены на анализ вибрационного сигнала. ЭМД широко используется, но в разложенном сигнале возникают проблемы смещения мод, концевых эффектов, вне оболочки и т.д. [76]. РВР требует знания количества мод, что влияет на результат декомпозиции, точность, а также на вычислительные ресурсы и время [77]. АЭМД дает различный набор компонентов при каждом разложении сигнала, что не позволяет использовать его для мониторинга и прогнозирования неисправностей. Комбинирование АЭМД с анализом независимых компонент

(АНК) позволяет более эффективно выделять признаки сложных неисправностей [78]. Однако недостатком является сложность реализации, связанная с использованием датчиков вибрации, которые предъявляют жесткие требования к месту их установки и требуют прокладки дополнительных кабелей для связи с блоком обработки данных. В нефтегазовой промышленности доступ к оборудованию (например, погружным насосам) ограничен, а в некоторых случаях возникают дополнительные паразитные вибрации, искажающие результаты анализа, например, на буровых установках. В таких условиях использование вибрационных методов для диагностики АД практически невозможно. Согласно многим исследованиям, разрушение подшипников вызывает наиболее сильное искажение магнитного поля воздушного зазора АД, которое проявляется в виде синусоидального искажения потребляемого тока статора. Для выявления неисправностей на основе анализа тока часто используется быстрое преобразование Фурье с последующим анализом частотного спектра. Недостатками этого метода являются его чувствительность к ряду факторов и необходимость получения дополнительной информации. Например, если механическая нагрузка двигателя изменяется во времени, то при спектральном анализе тока статора следует учитывать, что появление совершенно одинаковых частотных составляющих может иметь разные причины. Кроме того, БПФ-разложение исходной функции на элементарные составляющие приводит к разложению на гармонические колебания различных частот, что делает невозможным выявление и отслеживание обобщенного сигнала, порожденного дефектом, и его прогрессирования при различных условиях нагрузки. Асинхронные двигатели широко используются в промышленности для решения различных задач, в том числе для работы с сильно изменяющимися во времени нагрузками. В частности, медленные и нестационарные процессы характерны для насосных и компрессорных систем. Переменные нагрузки создают дополнительные составляющие в спектре тока двигателя, которые могут маскировать признаки неисправности самого двигателя. Как следствие, при анализе спектра тока двигателя сложно определить и отличить сигнатуры, связанные с реальными неисправностями, от сигнатур, связанных с изменчивостью нагрузки двигателя. В некоторых случаях для использования метода диагностики на основе частотного анализа сначала получают эталонный спектр, соответствующий нормальному рабочему состоянию двигателя; когда в спектре появляются новые компоненты, это указывает на наличие неисправности. Этот подход имеет ограничения, связанные с отсутствием эталонного спектра в реальном производстве.

Четвертая промышленная революция оказывает все большее влияние на методы мониторинга состояния. Развитие онлайн-мониторинга с возможностями туманных вычислений, обеспечивающих непрерывный сбор данных с датчиков и вычисления в системах технического обслуживания, требует исследований в области больших данных и машинного обучения. Интеграция интеллектуальных систем электроснабжения в производство и доступность электрических данных с распределительных узлов делают привлекательным использование электрических параметров для обнаружения неисправностей. Поэтому в данной работе предлагается использовать метод сингулярного разложения по начальной выборке, примененный к сигналу тока статора электродвигателя, для выявления закономерностей, характеризующих возникновение и развитие неисправности подшипника.

3. Методика проведения экспериментов

Сбор данных о текущих сигналах для последующего анализа проводился в лабораториях Учебно-исследовательского центра цифровых технологий Санкт-Петербургского горного университета. Необходимость проведения эксперимента была обусловлена недоступностью реальных производственных данных и отсутствием аналогичных наборов данных в открытом доступе в сети Интернет. Высокочастотная оцифровка аналогового сигнала со скоростью 600 000 точек/мин, что соответствует частоте дискретизации 10 кГц, была использована для исследования и подтверждения гипотез о возможности раннего обнаружения неисправностей подшипников. В дальнейшем предполагается изучить требования к граничной частоте дискретизации для обнаружения неисправностей с помощью предложенного алгоритма.

Неисправность подшипника была выбрана как один из наиболее распространенных типов дефектов и как классический пример для рассмотрения эффективности предлагаемого метода. Экспериментальная методика заключается в искусственном разрушении внутренних колец подшипника в виде серии раковин, вызванных трением, в шарикоподшипнике с глубокой канавкой. Таким образом, искусственно создавалось образование усталостных раковин. Следует отметить, что возникновение раковин в подшипниках не всегда обусловлено процессом усталостного разрушения материала, а также

носит достаточно длительный характер и не обнаруживается при анализе вибрационных сигналов на ранних стадиях развития [79]. Исходя из этих соображений, градация развития дефекта подшипника определяется одной раковинной (ранняя стадия) и тремя усталостными раковинами (а также ранней стадией с более заметным присутствием в сигнале).

Эксперименты проводились на асинхронном двигателе AIR132M4, $P_{nom}=11$ кВт, питаемом сетевым напряжением 50 Гц в режиме непрерывной работы и с постоянной нагрузкой на вал во время испытаний (табл. 1).

Таблица 1

Паспорт асинхронного двигателя

Марка двигателя	P_{nom} , кВт	I_{nom} , А	n , об/мин	$\cos \phi$	η_m , %	λ	K_p	K_i
AIR132M4	11,00	23,40	1450	0,82	87,1	2,3	2,2	6,8

P_{nom} – номинальная мощность двигателя, кВт; I_{nom} – номинальный ток двигателя, А; n – скорость вращения вала двигателя, об/мин; η_m – КПД двигателя; $\cos \phi$ – коэффициент мощности; λ – перегрузочная способность; K_p – кратность пускового момента; K_i – кратность пускового тока.

Электродвигатели AIR для общепромышленного применения являются наиболее популярными в промышленности для привода насосов, компрессоров, вентиляторов, станков, мельниц, шлифовальных машин и транспортных механизмов. Они имеют прочную конструкцию, хорошие пусковые, вибрационные и акустические характеристики. Внешний вид и электрическая схема АД приведены на рисунке 1. Постоянная нагрузка контролируется электромагнитным тормозом (ЭМТ). Сбор данных с высокой частотой дискретизации был реализован с помощью универсального шасси NI PXI-1042 и многофункционального модуля ввода/вывода PXI-6251.




Рис. 1. Общая схема исследования, включая алгоритм SSA

Эксперимент проводился в трех состояниях машины:

- 1) работа исправного двигателя в стандартных условиях при номинальной нагрузке;
- 2) работа двигателя с одной раковиной на внутреннем кольце подшипника при номинальной нагрузке;
- 3) работа двигателя с тремя раковинами на внутреннем кольце подшипника при номинальной нагрузке.

Для данного эксперимента был исследован однорядный радиальный шарикоподшипник закрытого типа 6208 ZZ C3 с экранами (рис. 2, табл. 2).




Рис. 2. Подшипник 6208 ZZ C3

Таблица 2

Паспорт подшипника

Марка подшипника	d	D	B	r	C_r , Н	C_{0r} , Н	C_r , кгс	C_{0r} , кгс	f	N_{max} , об/мин (Смазка)	N_{max} , об/мин (Масло)
6208 ZZ C3	40	80	18	1.1	29,100	17,900	2970	1820	14	8500	10,000

D , d , B , r – размеры подшипника, мм; C_r , C_{0r} – базовая динамическая и статическая грузоподъемность; f – коэффициент, зависящий от геометрии деталей подшипника; N_{max} – предельная частота вращения при различных способах смазки, об/мин.

Можно рассчитать срок службы каждого компонента асинхронного двигателя, включая подшипники, но на практике определенный процент подшипников выходит из строя раньше срока. На протяжении всего жизненного цикла подшипника можно выделить основные этапы, оказывающие значительное влияние на срок службы: монтаж и смазка подшипника, центровка, повторное смазывание, контроль состояния и демонтаж. Наиболее распространенными причинами повреждения подшипников являются нарушения смазки (36 %), нарушения монтажа (16 %), загрязнение смазки (14 %) и усталостный износ (34 %). Обнаружение развивающегося дефекта позволяет значительно продлить срок службы подшипника, тем самым повышая эффективность и производительность оборудования, в котором используется АД.

В качестве экспериментальных данных использовались три временных ряда потребления тока и напряжения двигателя: первый набор данных был без дефектов; два набора имели 1 или 3 дефекта одного типа, соответственно (раковины на внутреннем кольце подшипника) на заднем торцевом щите. Эти временные ряды имели идентичную синусоидальную структуру, однако присутствовали незначительные искажения, природа которых визуально не определялась (рис. 3).




Рис. 3. Токвые сигналы для подшипника без повреждений, подшипника с одной раковинной и подшипника с тремя раковинами

Как видно из осциллограмм, наличие дефекта с одной раковинной не вносит вклада в искажения тока и напряжения. Дальнейшее развитие дефекта проявляется как искажение тока, но на напряжении этого не происходит. Поэтому в нашем случае сигналы напряжения не представляют интереса (рис. 4). Однако в случае реального процесса напряжения могут содержать искажения, обусловленные наличием нелинейной и резко изменяющейся нагрузки на общей шине питания [80]. В этом случае временные ряды напряжения должны использоваться для поиска этих искажений и исключения их влияния на результат обнаружения неисправностей, и последующие исследования могут быть направлены именно на это.




Рис. 4. Сигналы напряжения для подшипника без повреждений, подшипника с одной раковинной и подшипника с тремя раковинами

4. Выполнение сингулярного спектрального анализа

Основой алгоритма обнаружения неисправностей является метод сингулярного спектрального анализа (ССА) для обработки сигналов тока статора. ССА основан на разложении временного ряда на элементарные аддитивные компоненты, что позволяет рассмотреть и исследовать его структуру [81, 82].

Метод ССА заключается в преобразовании одномерного ряда в многомерный с помощью однопараметрической процедуры сдвига, исследовании полученной многомерной траектории с помощью анализа главных компонент (сингулярного разложения) и восстановлении (аппроксимации) ряда по выбранным главным компонентам. Результатом метода является разложение временного ряда на простые компоненты: тренды, периодические или осцилляторные компоненты и шумовые компоненты. Полученные компоненты разложения и их вариации сопоставляются с режимом работы и уровнем неисправности подшипника. Выделение необходимых компонентов может стать основой для прогнозирования как самого временного ряда, так и его отдельных составляющих по мере прогрессирования неисправности и достижения предельных значений. При этом метод не требует стационарности ряда, знания тренда или наличия гармонических и циклических составляющих в ряду.

Предложенный алгоритм, основанный на сингулярном разложении, может быть использован для выявления компонентов, связанных с повреждениями, сглаживания временных рядов, исследования изменений в процессе деградации подшипника и эволюции повреждений подшипника, вызванных износом.

4.1. Встраивание (построение матрицы траекторий)

Записанные в файл сигналы фазового тока АД при определенном режиме нагрузки и уровне дефектов были преобразованы в вектор X , представляющий собой упорядоченный набор из N мгновенных значений тока. Затем выполнялась процедура встраивания, представляющая собой преобразование исходного одномерного ряда $X = [x_1, \dots, x_N]$ длины N в последовательность L -мерных векторов, число которых было равно $K = N - L + 1$; L – длина окна, $1 < L < N$:

$$X_i = (x_{i-1}, \dots, x_{i+L-1})^T, \quad 1 \leq i \leq K. \quad (1)$$

Эти векторы образовали траекторную матрицу $X = [X_1 : \dots : X_K]$ исходного временного ряда, которая является матрицей Ханкеля и имеет одинаковые элементы на диагонали $i + j = \text{const}$:

$$X = \begin{bmatrix} x_1 & x_2 & x_3 & \cdots & x_K \\ x_2 & x_3 & x_4 & \cdots & x_{K+1} \\ x_3 & x_4 & x_5 & \cdots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \cdots & x_N \end{bmatrix} \quad (2)$$

4.2. Разложение сингулярных значений

Сингулярное разложение для матрицы $A \in R_{m \times n}$ – это разложение следующего вида:

$$A = U \Sigma V^T, \quad (3)$$

где $U = (u_1, u_2, \dots, u_m) \in R^{m \times m}$ – унитарная матрица левых сингулярных векторов, $V = (v_1, v_2, \dots, v_n) \in R^{n \times n}$ – унитарная матрица правых сингулярных векторов, Σ – диагональная матрица размера $m \times n$ (рис. 5), диагональными элементами которой являются неотрицательные значения сингулярных величин матрицы A в порядке убывания, $\Sigma = [\text{diag}(\sigma_1, \sigma_2, \dots, \sigma_m), 0] \in R^{m \times n}$, $\sigma_1 \geq \sigma_2 \geq \dots, \sigma_m > 0$ [72, 83].




Рис. 5. Схематическое представление РСЗ

Матрица A также представима в виде суммы подматриц:

$$A = \begin{bmatrix} | & | & \cdots & | \\ u_1 & u_2 & \cdots & u_r \\ | & | & \cdots & | \end{bmatrix} \times \begin{bmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_r \\ 0 & 0 & \cdots & 0 \end{bmatrix} \times \begin{bmatrix} - & v_1^T & - \\ - & v_2^T & - \\ \vdots & \vdots & \vdots \\ - & v_r^T & - \end{bmatrix} = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \dots + \sigma_m u_m v_m^T = \sum_{i=1}^r A_i, \quad (4)$$

где $r = \min(m, n)$ – ранг матрицы A ; соответственно, $A_i = \sigma_i u_i v_i^T$, ($i = 1, 2, \dots, r$) – подматрица i -го субсигнала.

Для разложения матрицы траекторий X , полученной на предыдущем шаге, рассмотрим матрицу $S = XX^T$, собственные значения которой $\lambda_1 \geq \dots \geq \lambda_L \geq 0$ неотрицательны и расположены в порядке убывания. Пусть $d = \text{rank } X = \max\{j : \lambda_j > 0\}$, $U_1, \dots, U_L$ – соответствующие собственные векторы матрицы S , а $V_j = X^T U_j / \sqrt{\lambda_j}$, $j = 1, \dots, d$ – факторные векторы.

Разложение матрицы траекторий может быть записано следующим образом:

$$X = X_1 + \dots + X_d, \quad X_j = \sqrt{\lambda_j} U_j V_j^T, \quad (5)$$

где $(\sqrt{\lambda_j} U_j V_j^T)$ – j -й собственный вектор сингулярного разложения, содержащий сингулярное значение $\sigma_j = \sqrt{\lambda_j}$, левый сингулярный вектор U_j и правый сингулярный вектор V_j траекторной матрицы X .

В результате применения метода РСЗ мы получаем

$$X = \sum_i X_i, \quad X_i = \sigma_i U_i V_i^T. \quad (6)$$

Визуализация матрицы разложенной траектории на составляющие необходима для того, чтобы заранее оценить структуру составляющих. Пример такой визуализации для А-фазы сигнала представлен на рисунке 6. Сводка результатов декомпозиции для всех фаз представлена на рисунке 7.




Рис. 6. Построение матриц траекторий для фазы А и их разложение на 12 компонентов для подшипника без дефектов, подшипника с одной раковинной и подшипника с тремя раковинами




Рис. 7. Сравнение разложения матрицы траекторий всех рассматриваемых сигналов: подшипник без дефектов (а-с); подшипник с одной раковинной (d-f); подшипник с тремя раковинами (g-i); фаза А (а, d, g); фаза В (b, e, h); фаза С (с, f, i)

4.3. Группировка компонентов

Этот шаг основан на уравнении (1). Пусть $I = \{i_1, \dots, i_p\} \subset \{1, \dots, d\}$, тогда результирующая матрица X_I , соответствующая группе I , определяется как $I = X_{i_1} + \dots + X_{i_p}$. Процедура группировки разбивает весь набор индексов $\{1, \dots, d\}$ на m непересекающихся подмножеств $I_1, \dots, I_m$. Тогда декомпозиция (уравнение (5)) может быть записана в виде:

$$X = X_{I_1} + \dots + X_{I_m}. \quad (7)$$

Процедура выборки подмножеств $I_1, \dots, I_m$ представляет собой процедуру группировки собственных троек.

В данном исследовании рассматривается несколько подходов к кластеризации, результаты которой обобщены в таблице 4. Авторы рассматривают результаты группировки на основе визуальной оценки сходства структуры матрицы компонентов, метод, основанный на двумерных диаграммах рассеяния, и группировку на основе W -корреляционной матрицы.

4.4. Реконструкция исходного сигнала

На последнем шаге алгоритма каждая из матриц X_{lm} разложения (уравнение (7)) преобразуется обратно в исходную форму объекта X . Эта операция реализуется с помощью ханкелизации матриц (усреднение по диагонали). На выходе получается матрица, наиболее близкая по норме Фробениуса, которая соблюдает свойства матрицы Ханкеля и сохраняет ее размер.

Пусть $Y \in R^{L \times K}$, $1 \leq i \leq L$, $1 \leq j \leq K$. Обычно $L < K$, но для общности пусть $L^* = \min(L, K)$, $K^* = \max(L, K)$ и $N = L + K - 1$. Пусть $y_{iy}^* = y_{ij}$ при $L < K$, и $y_{iy}^* = y_{ji}$ в противном случае. Пусть $s = i + j$, тогда диагональное уравнение усреднения для матрицы Y принимает вид:

$$\tilde{y}_{ij} = \begin{cases} \frac{1}{s-1} \sum_{l=1}^{s-1} y_{l,s-l}^* & \text{for } 2 \leq s \leq L^*, \\ \frac{1}{L^*} \sum_{l=1}^{L^*} y_{l,s-l}^* & \text{for } L^* \leq s \leq K^* + 1, \\ \frac{1}{N-s+2} \sum_{l=s-K^*}^{L^*} y_{l,s-l}^* & \text{for } K^* + 2 \leq s \leq N + 1. \end{cases} \quad (8)$$

Диагональное усреднение, примененное к каждой результирующей матрице компонентов, создает реконструированный временной ряд. Таким образом, исходный ряд разлагается в сумму реконструированных рядов.

5. Результаты и обсуждение

На основе представленного алгоритма декомпозиции и группировки были обработаны токовые сигналы трех фаз асинхронного двигателя в рассматриваемых режимах работы.

На рисунке 7 представлены первые 12 компонент исходного ряда в виде элементарных матриц Ханкеля, расположенных в порядке убывания их вклада в реконструированный временной ряд. В литературе нет практических рекомендаций по количеству компонент, которые следует учитывать при анализе повреждений. Количество типов возможных факторов, формирующих текущий сигнал, может быть использовано для обоснования рассмотрения не более 12 компонент из 350 сингулярных значений, используемых при разложении. К факторам, влияющим на токовый сигнал, помимо конструктивных особенностей двигателя и нагрузки, относится также наличие дефектов. Следовательно, количество возможных дефектов является пределом, который необходимо учитывать для значимых компонент. К неисправностям, которые могут быть обнаружены по электрическим сигналам, относятся разрушение подшипников, перекося вала, межфазные замыкания, эксцентриситет и обрыв стержня ротора.

Характерные изменения в нескольких компонентах, выделенных на рисунке, можно обнаружить визуально. По мере появления и увеличения дефекта нестационарная составляющая увеличивает свой вклад в общую структуру сигнала, что приводит к увеличению порядкового номера. Следует отметить, что при наличии трех раковин (то есть при явном появлении дефекта) во всех фазах $\tilde{X}_2$ появляется вырожденная компонента: $\det(\tilde{X}_2) \rightarrow 0$.

Оценка относительных вкладов компонент в матрицу траекторий, а также суммарный вклад рассчитываются по следующим уравнениям:

$$RC_i = \frac{\sigma_i^2}{\sum_{k=0}^{d-1} \sigma_k^2}, \quad \sum_{i=0}^d RC_i = \frac{\sum_{j=0}^i \sigma_j^2}{\sum_{k=0}^{d-1} \sigma_k^2}. \quad (9)$$

Графики на рисунке 8 показывают относительный и суммарный вклад первых 12 компонентов. Из-за значительного вклада первых двух компонентов графики представлены парами: верхние

графики в каждом режиме включают все компоненты, а последующие (нижние) графики исключают первые два компонента для более наглядного представления.




Рис. 8. Относительный и суммарный вклад компонентов: $[0, \dots, 11]$ (слева), $[2, \dots, 11]$ (справа) для фазы А подшипника без дефектов (а), подшипника с одной раковинной (б) и подшипника с тремя раковинами (с)

Полный результат расчета вклада компонентов представлен в таблице 3.

Таблица 3

Сравнение результатов, полученных при расчете вклада компонентов

№ п/п	Относительный вклад			Совокупный вклад		
	Рабочее состояние	1 раковина	3 раковины	Рабочее состояние	1 раковина	3 раковины
Фаза А						
0	54,588734	56,928886	52,862365	54,588734	56,928886	52,862365
1	45,365214	43,030047	46,825041	99,953948	99,958933	99,687407
2	0,005713	0,006323	0,259554	99,959661	99,965256	99,946961
3	0,005507	0,002725	0,006455	99,965169	99,96798	99,953416
4	0,003133	0,002691	0,006271	99,968302	99,970671	99,959687
5	0,002687	0,00214	0,005474	99,970989	99,972811	99,965161

№ п/п	Относительный вклад			Совокупный вклад		
	Рабочее состояние	1 раковина	3 раковины	Рабочее состояние	1 раковина	3 раковины
6	0,002667	0,002054	0,002385	99,973656	99,974865	99,967546
7	0,002657	0,001333	0,002383	99,976313	99,976197	99,969928
8	0,00263	0,001311	0,002319	99,978943	99,977508	99,972247
9	0,001364	0,001263	0,002208	99,980308	99,978772	99,974456
10	0,001339	0,00125	0,001797	99,981646	99,980022	99,976253
11	0,001077	0,001114	0,001792	99,982723	99,981136	99,978045
Фаза В						
0	53,291363	54,165786	56,725008	53,291363	54,165786	56,725008
1	46,668971	45,80813	43,042536	99,960334	99,973915	99,9767544
2	0,004136	0,002663	0,196508	99,96447	99,976578	99,964052
3	0,004097	0,002637	0,004419	99,968566	99,979215	99,96847
4	0,002899	0,001347	0,004193	99,971465	99,980562	99,972664
5	0,002669	0,001284	0,002074	99,974134	99,981845	99,974738
6	0,002222	0,001078	0,001842	99,976355	99,982923	99,97658
7	0,002109	0,001074	0,00183	99,978464	99,983998	99,97841
8	0,002087	0,00073	0,001431	99,980551	99,984728	99,979841
9	0,001834	0,000696	0,001348	99,982385	99,985424	99,981189
10	0,001823	0,00068	0,001343	99,984208	99,986104	99,982533
11	0,000956	0,000639	0,001333	99,985164	99,986743	99,983865
Фаза С						
0	56,876428	53,698498	54,712877	56,876428	53,698498	54,712877
1	43,059692	46,248323	45,048668	99,936119	99,946822	99,9761545
2	0,023789	0,021773	0,171188	99,959908	99,968595	99,932733
3	0,00614	0,00317	0,024359	99,966048	99,971764	99,957092
4	0,005854	0,003154	0,008227	99,971903	99,974919	99,965319
5	0,002469	0,001771	0,00797	99,974372	99,97669	99,973289
6	0,00245	0,001725	0,002551	99,976822	99,978414	99,97584
7	0,002245	0,001343	0,002525	99,979067	99,979757	99,978365
8	0,002236	0,001341	0,00143	99,981303	99,981098	99,979795
9	0,001323	0,001026	0,001423	99,982626	99,982125	99,981218
10	0,001185	0,001019	0,001344	99,983811	99,983144	99,982562
11	0,001128	0,000945	0,001319	99,984939	99,984089	99,983881

Результаты оценки показывают, что первые 12 сингулярных значений описывают 99,98 % общей информации исходного сигнала во всех трех режимах, поэтому значительная потеря информативности исключена. Выделив компоненты, которые изменяются на диагностической карте компонентов (рис. 7) при возникновении скола, мы можем сравнить увеличение вклада с увеличением дефектов. Как видно из таблицы 3, суммарный вклад компонентов $\tilde{X}_0$ и $\tilde{X}_1$ составляет более 99 %, что делает невозможным отследить проявление дефекта на ранней стадии. Не было выявлено и явной корреляции между изменениями этих компонент и наличием скола.

При наличии трех раковин общее увеличение вклада этих компонент по сравнению с нормальным состоянием было незначительным. Для однозначной оценки вклада и определения проявления изменения компонент в токовом сигнале, обусловленного наличием начальной стадии дефекта, необходимо было выделить группы компонент низшего порядка, которые меняли свое положение по уровню вклада при наличии повреждения, и оценить изменение их вклада во всех трех состояниях.

Кроме того, определить количество информативных компонент можно на основе матриц сходства главных компонент, рассчитанных по расстоянию между парами матриц Ханкеля

$$\|X\|_F = \sqrt{\sum_{i=1}^L \sum_{j=1}^K |x_{ij}|^2}, \quad (10)$$

где $\|X\|_F$ – норма Фробениуса. Анализируя матрицу расстояний (рис. 9), можно выделить четкую границу в диапазоне $\tilde{F}_{ij} = [10, \dots, 20]$, что подтвердило сходство первых компонент и отбросило неинформативные компоненты $\tilde{F}_{ij} = [20, \dots, 350]$.




Рис. 9. Матрица расстояний на основе нормы Фробениуса для фазы А подшипника без дефектов, слева – для полного набора компонент (350), справа – для исследованного набора информативных компонент (20)

Реконструкция временного ряда по результатам группировки компонент на основе визуальной оценки структуры матрицы показана на рис. 10.

В связи с тем, что компоненты плохо поддаются визуальному разделению, для проверки гипотез группировки компонент на основе визуального сравнения матриц траекторий мы предлагаем использовать двумерные скаттерграммы и группировку на основе W -корреляционной матрицы.

Двумерные скаттерграммы – это попарные представления собственных векторов V_i и V_{i+1} для поиска пар собственных векторов, соответствующих одной и той же гармонике. Свойство ортогональности собственных векторов позволило идентифицировать гармонику как образ замкнутой кривой правильной формы (рис. 11).




Рис. 10. Результаты группировки компонентов на основе визуальной оценки для фазы А подшипника без дефектов (а), подшипника с одной раковинной (б) и подшипника с тремя раковинами (с)




Рис. 11. Диаграммы рассеяния собственных векторов для фазы А подшипника без дефектов, подшипника с одной раковины и подшипника с тремя раковинами

Согласно рисунку, плавная форма круга представляет собой четкую взаимосвязь между компонентами 1 и 2 в каждом из рассматриваемых случаев. Аналогично, мы можем объединить компоненты 5, 6, 7 и 8 для подшипника без дефектов, поскольку они имеют схожую форму замкнутых кривых. Кроме того, для обоих случаев подшипников с выбоинами мы не смогли объединить компонент 2 ни с одной из соседних групп. Для проверки и количественной оценки степени разделимости между элементарными компонентами используется W -корреляционная матрица. Анализ корреляционной матрицы выявляет пары коррелирующих компонентов и объединяет их в группы. Затем определяется мера разделимости между двумя реконструированными временными рядами $\tilde{F}_i$ и $\tilde{F}_j$ следующим образом:

$$W_{ij} = \frac{(\tilde{F}_i, \tilde{F}_j)_w}{\|\tilde{F}_i\|_w \|\tilde{F}_j\|_w}, \quad (11)$$

где $(\tilde{F}_i, \tilde{F}_j)_w$ – взвешенное внутреннее (скалярное) произведение, $(\tilde{F}_i, \tilde{F}_j)_w = \sum_{k=0}^{N-1} w_k \tilde{f}_{i,k} \tilde{f}_{j,k}$; $\tilde{f}_{i,k}, \tilde{f}_{j,k}$ – k -е значения $\tilde{F}_i$ и $\tilde{F}_j$ соответственно; $w_k = \min\{k, L, N - k + 1\}$; $\|\tilde{F}_k\|_w = \sqrt{(\tilde{F}_k, \tilde{F}_k)_w}$ для

$k = i, j$. Чем меньше значение W_{ij} , тем выше разделимость компонент; соответственно, если восстановленные $\tilde{F}_i$ и $\tilde{F}_j$ близки друг к другу, то $(\tilde{F}_i, \tilde{F}_j)_w \rightarrow \|\tilde{F}_i\|_w \|\tilde{F}_j\|_w$, а $W_{ij} \rightarrow 1$. $W_{ij} = 0$, если $\tilde{F}_i$ и $\tilde{F}_j$ ортогональны. Данная зависимость (мера) необходима для расчета несходства при выполнении иерархической кластеризации для автоматической группировки компонент: $d(i, j) = 1 - |W_{ij}|$.

Метод иерархической кластеризации заключается в последовательной группировке схожих пар на основе расстояний; группировка продолжается до тех пор, пока все объекты не образуют единый кластер. В результате получается дерево групп, называемое дендрограммой, которое отражает взаимные связи между объектами в данном наборе (рис. 12). Количество групп зависит от порогового значения; чем выше пороговое значение (ось Y), тем меньше количество выходных групп.

В таблице 4 представлены результаты метода иерархической кластеризации и сравнение с группировкой по скаттерграммам и визуальной группировкой на основе матриц Ханкеля. Сочетание основных компонент $\tilde{X}_0$ и $\tilde{X}_1$ имело место при всех методах группировки независимо от режима, обусловленного уровнем дефектности подшипника. Вторая группа варьировалась в зависимости от метода группировки, нумерации фаз и режима, но в основном в эту группу попадал компонент, а в вариантах, где добавлялись другие компоненты, всегда присутствовал компонент $\tilde{X}_3$. По мере роста дефекта наблюдалось постоянное увеличение компонента $\tilde{X}_2$ и уменьшение компонента $\tilde{X}_3$, причем эти тенденции всегда были противоположными. По мере роста дефекта во всех фазах происходила перегруппировка, и компонент группировался с компонентом, равным по вкладу, а компонент $\tilde{X}_2$ выделялся в отдельную группу с наибольшим вкладом и вырождался. Каждый метод группировки был уникально чувствителен к наличию дефекта: при наличии трех раковин группировка давала одинаковый результат независимо от метода. Наличие дефекта приводило к перераспределению компонентного состава и изменению уровня вклада. Однако на ранних стадиях деградации подшипника метод группировки на основе диаграммы рассеяния оказался более надежным для выделения компонентов в отдельную группу. Независимо от метода группировки, компоненты $\tilde{X}_2$ и $\tilde{X}_3$ были наиболее важны для отслеживания проявления дефектов.

Таблица 4

Сравнение результатов, полученных при группировке компонентов

	Визуальная группировка	Скаттерграммы	W-корреляционная матрица, пороговое значение 0,8	W-корреляционная матрица, пороговое значение 0,9
Без дефектов				
I_a	Тренд: [0, 1] Группа 1: [2, 3] Группа 2: [4] Группа 3: [9, 10, 11] Шум: [5, 6, 7, 8]	Тренд: [0, 1] Группа 1: [2, 3] Группа 2: [4] Группа 3: [5, 6, 7, 8] Группа 4: [9, 10, 11]	Тренд: [0, 1] Группа 1: [2, 3] Группа 2: [4] Группа 3: [5, 6, 7, 8] Группа 4: [9, 10, 11]	Тренд: [0, 1, 9, 10, 11] Группа 1: [2, 3, 5, 6, 7, 8] Группа 2: [4]
I_b	Тренд: [0, 1] Группа 1: [2, 3] Группа 2: [4, 5] Группа 3: [6] Шум: [7, 8, 9, 10, 11]	Тренд: [0, 1] Группа 1: [2, 3] Группа 2: [4, 5] Группа 3: [6] Группа 4: [7, 8] Группа 5: [9, 10] Группа 6: [11]	Тренд: [0, 1] Группа 1: [2, 3] Группа 2: [4, 5] Группа 3: [6] Группа 4: [7, 8] Группа 5: [9, 10] Группа 6: [11]	Тренд: [0, 1, 2, 3, 7, 8] Группа 1: [4, 5, 9, 10, 11] Группа 2: [6]
I_c	Тренд: [0, 1] Группа 1: [2, 9] Группа 2: [3, 4] Группа 3: [10, 11] Шум: [5, 6, 7, 8]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4] Группа 3: [5, 6] Группа 4: [7, 8] Группа 5: [9, 10, 11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4] Группа 3: [5, 6] Группа 4: [7, 8] Группа 5: [9, 10, 11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4, 5, 6, 9, 10, 11] Группа 3: [7, 8]
1 раковина				
I_a	Тренд: [0, 1] Группа 1: [2] Группа 2: [5, 6] Группа 3: [7, 8, 11] Шум: [3, 4, 9, 10]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4] Группа 3: [5, 6] Группа 4: [9, 10] Группа 5: [7, 8, 11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4] Группа 3: [5, 6] Группа 4: [7, 8, 11] Группа 5: [9, 10]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4, 7, 8, 11] Группа 3: [5, 6, 9, 10]

	Визуальная группировка	Скаттерграммы	W-корреляционная матрица, пороговое значение 0,8	W-корреляционная матрица, пороговое значение 0,9
I_b	Тренд: [0, 1] Группа 1: [4, 5] Группа 2: [8, 11] Группа 3: [9, 10] Шум: [2, 3, 6, 7]	Тренд: [0, 1] Группа 1: [2, 3] Группа 2: [4, 5] Группа 3: [6, 7] Группа 4: [8, 9, 10, 11]	Тренд: [0, 1] Группа 1: [2, 3, 8, 9, 10, 11] Группа 2: [4, 5] Группа 3: [6, 7]	Тренд: [0, 1, 4, 5] Группа 1: [2, 3, 6, 7, 8, 9, 10, 11]
I_c	Тренд: [0, 1, 7] Группа 1: [2, 3] Группа 2: [4, 5] Группа 3: [6, 8] Шум: [9, 10, 11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4] Группа 3: [5, 6, 7, 8] Группа 4: [9, 10] Группа 5: [11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4] Группа 3: [5, 6, 7, 8] Группа 4: [9, 10] Группа 5: [11]	Тренд: [0, 1, 11] Группа 1: [2, 5, 6, 7, 8] Группа 2: [3, 4] Группа 3: [9, 10]
3 раковины				
I_a	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4, 8, 9] Группа 3: [5] Шум: [6, 7, 10, 11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4, 5] Группа 3: [6, 7] Группа 4: [8, 9] Группа 5: [10, 11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4, 5] Группа 3: [6, 7, 8, 9] Группа 4: [10, 11]	Тренд: [0, 1, 6, 7, 8, 9] Группа 1: [2] Группа 2: [3, 4, 5, 10, 11]
I_b	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4, 8, 11] Группа 3: [5] Шум: [6, 7, 9, 10]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4] Группа 3: [5] Группа 4: [6, 7] Группа 5: [8] Группа 6: [9, 10] Группа 7: [11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3, 4] Группа 3: [5] Группа 4: [6, 7] Группа 5: [8, 11] Группа 6: [9, 10]	Тренд: [0, 1, 3, 4, 8, 11] Группа 1: [2] Группа 2: [5] Группа 3: [6, 7, 9, 10]
I_c	Тренд: [0, 1] Группа 1: [2] Группа 2: [3] Группа 3: [4, 5, 10, 11] Шум: [6, 7, 8, 9]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3] Группа 3: [4, 5] Группа 4: [6, 7] Группа 5: [8, 9] Группа 6: [10, 11]	Тренд: [0, 1] Группа 1: [2] Группа 2: [3] Группа 3: [4, 5] Группа 4: [6, 7] Группа 5: [8, 9] Группа 6: [10, 11]	Тренд: [0, 1, 10, 11] Группа 1: [2] Группа 2: [3] Группа 3: [4, 5, 6, 7, 8, 9]

Показателями для отслеживания могут служить структура компонентов, составляющих группу, и общий вклад, который они вносят в общий сигнал. В будущем необходимо провести анализ результатов группировки различными способами, чтобы проверить гипотезу о разложении и взаимной корреляции при наличии нескольких комбинаций уровней и типов дефектов. Также представляет интерес снижение разрешения данных до уровня, при котором метод группировки на основе диаграммы рассеяния теряет способность выявлять начальную и продвинутой стадии дефекта.

6. Выводы

Выявление неисправностей вращающегося оборудования в целом и асинхронных двигателей в частности на основе анализа электрических параметров является достаточно трудоемкой, но актуальной и перспективной задачей в связи со сложными условиями эксплуатации оборудования. Выявление уязвимостей на ранней стадии развития в отдельных компонентах позволит продлить жизненный цикл всего технологического процесса и значительно снизить энергопотребление и выбросы.

В данной работе авторы предложили подход, основанный на сингулярном разложении исходной выборки, примененный к сигналу тока статора электродвигателя для выявления закономерностей, характеризующих возникновение и развитие неисправности подшипника. Для проверки гипотезы о выделении компонентов с помощью ССА и РСЗ были проведены эксперименты, результаты которых исследовались с помощью оценки вклада компонентов; для проверки рассматривались двумерные диаграммы рассеяния и группировка методом иерархической кластеризации на основе взвешенной корреляционной матрицы.

Результаты показали тенденцию к выделению компонентов в отдельные группы; эта тенденция проявлялась в каждом из указанных подходов к группировке; кроме того, вклад этих сгруппированных компонентов возрастал на порядок по мере прогрессирования повреждения. Анализ

полученных результатов позволяет авторам сделать вывод о том, что именно эти компоненты с наибольшей вероятностью ответственны за развитие дефекта, тем самым подтверждая возможность идентификации дефекта на ранней стадии на основе текущей сигнатуры с помощью предложенного алгоритма.

Предложенная методика имеет преимущества перед классическими методами благодаря отсутствию необходимости в дополнительных датчиках и отсутствию дополнительных знаний об исходном временном ряде.

Для дальнейшей работы авторов представляют интерес исследования других типов неисправностей, комбинаций типов и уровней неисправностей, а также последующий анализ электрических сигналов с использованием сингулярного разложения.

Кроме того, будущие исследования включают в себя:

- исследование требований к граничной частоте дискретизации для обнаружения неисправностей с помощью предложенного алгоритма;
- тестирование предложенного алгоритма на других неочевидных типах неисправностей, таких как несоосность и ослабление креплений двигателя;
- создание карты компонентов с использованием представленных подходов для отдельного электромеханического оборудования.

Выявление неисправностей на ранних стадиях и мониторинг изменений позволят грамотно управлять техническим обслуживанием и ремонтом и повышать уровень энергоэффективности, исходя из технического состояния оборудования.

Вклад авторов: концептуализация, Ю.Ж. и А.В.; методология, Ю.Ж. и И.Р.; программное обеспечение, А.В.; валидация, И.Р.; формальный анализ, А.В.; исследование, А.В.; обработка данных, Ю.Ж.; написание – подготовка первоначального проекта, А. В.; написание – первоначальная подготовка проекта, Ю.Ж. и И.Р.; визуализация, А.В.; руководство, Ю.Ж.; администрирование проекта, Ю.Ж. Все авторы прочитали и согласились с опубликованной версией рукописи.

Финансирование: исследование выполнено за счет средств субсидии на выполнение государственного задания в сфере научной деятельности на 2023 г. «Фундаментальные междисциплинарные исследования недр Земли и процессов комплексного освоения георесурсов» № ФСРВ-2023-0002.

Заявление о доступности данных: данные, представленные в настоящем исследовании, доступны по запросу у соответствующего автора.

Благодарности: авторы выражают благодарность Учебно-научному центру цифровых технологий Санкт-Петербургского горного университета и Николаю Королеву за предоставленное оборудование, а также Георгию Баранову из Университета ИТМО за помощь в сборе данных.

Конфликты интересов: авторы заявляют об отсутствии конфликта интересов.

Сокращения

ANN	ИНС	Искусственная нейронная сеть
CO ₂	CO ₂	Диоксид углерода
DSS	СППР	Система поддержки принятия решений
EEMD	АЭМД	Ансамблевое эмпирическое разложение мод
EMB	ЭМТ	Электромагнитный тормоз
EMD	ЭМД	Эмпирическое разложение режимов
FFT	БПФ	Быстрое преобразование Фурье
ICA	АНК	Анализ независимых компонент
IM	АД	Асинхронный двигатель
MRO	ТОР	Техническое обслуживание и ремонт
RPM	об/мин	Обороты в минуту
SES	КОС	Квадратичная огибающая спектра
SSA	ССА	Сингулярный спектральный анализ
STMS	КСМР	Краткосрочные матричные ряды
SVD	РСЗ	Разложение сингулярного значения
SVD-AF	АФ-РСЗ	Амплитудный фильтр разложения сингулярного значения
SVR	НСЗ	Нормирование сингулярного значения
VMD	РВР	Разложение вариационного режима

ЛІТЕРАТУРА

1. Modarres, M.; Kaminskiy, M.; Krivtsov, V. *Reliability Engineering and Risk Analysis: A Practical Guide*; CRC: Boca Raton, FL, USA, 1999.
2. Ustinov, D.A.; Shafhatov, E.R. Assessment of Reliability Indicators of Combined Systems of Offshore Wind Turbines and Wave Energy Converters. *Energies* 2022, 15, 9630. <http://doi.org/10.3390/en15249630>
3. Dodson, B.; Nolan, D. *Reliability Engineering Handbook*; CRC: Boca Raton, FL, USA, 1999.
4. Brighton, S.; Long, Z.; Bunda, B. Evaluating and optimizing the effectiveness of mining equipment; the case of Chibuluma South underground mine. *J. Clean. Prod.* 2020, 252, 119697. <http://doi.org/10.1016/j.jclepro.2019.119697>
5. Malyshev, G.B.; Sinkov, L.S.; Nikolaichuk, L.A. Analysis of economic evaluation methods of environmental damage at calculation of production efficiency in mining industry. *Int. J. Appl. Eng. Res.* 2017, 10, 2551–2554.
6. Dvoynikov, M.; Sidorov, D.; Kamburov, E.; Rose, F.; Ahiyarov, R. Salt Deposits and Brine Blowout: Development of a Cross-Linking Composition for Blocking Formations and Methodology for Its Testing. *Energies* 2022, 15, 7415. <http://doi.org/10.3390/en15197415>
7. IEA. Energy Efficiency Policy Opportunities for Electric Motor-Driven Systems. 2011. Available online: <https://www.iea.org/reports/energy-efficiency-policy-opportunities-for-electric-motor-driven-systems> (accessed on 24 November 2022).
8. IEA. Motor-Driven System Electricity Use as a Share of Electricity Use by Industry Subsector. 2020. Available online: <https://www.iea.org/data-and-statistics/charts/motor-driven-system-electricity-use-as-a-share-of-electricity-use-by-industry-subsector> (accessed on 24 November 2022).
9. New EU Rules to Boost Energy Efficiency of Electric Motors. Available online: https://ec.europa.eu/info/news/new-eu-rulesboost-energy-efficiency-electric-motors-2021-jun-30_en (accessed on 24 November 2022).
10. IEA. A Call to Action on Efficient and Smart Appliances. 2021. Available online: <https://www.iea.org/articles/a-call-to-actionon-efficient-and-smart-appliances> (accessed on 24 November 2022).
11. Korolev, N.; Kozyaruk, A.; Morenov, V. Efficiency increase of energy systems in oil and gas industry by evaluation of electric drive lifecycle. *Energies* 2021, 14, 6074. <http://doi.org/10.3390/en14196074>
12. Khalturin, A.A.; Parfenchik, K.D.; Shpenst, V.A. Features of Oil Spills Monitoring on the Water Surface by the Russian Federation in the Arctic Region. *J. Mar. Sci. Eng.* 2023, 11, 111. <http://doi.org/10.3390/jmse11010111>
13. Tsvetkov, P. Engagement of resource-based economies in the fight against rising carbon emissions. *Energy Rep.* 2022, 8, 874–883. <http://doi.org/10.1016/j.egyr.2022.05.259>
14. Barabady, J.; Kumar, U. Reliability analysis of mining equipment: A case study of a crushing plant at Jajarm Bauxite Mine in Iran. *Reliab. Eng. Syst. Saf.* 2008, 93, 647–653. <http://doi.org/10.1016/j.res.2007.10.006>
15. Mitchell, Z. *A Statistical Analysis of Construction Equipment Repair Costs Using Field Data and the Cumulative Cost Model*; Virginia Polytechnic Institute: Blacksburg, VA, USA, 1998.
16. Ercelebi, S.; Bascetin, A. Optimization of shovel-truck system for surface mining. *J. S. Afr. Inst. Min. Metall.* 2009, 109, 433–439.
17. Salama, A.; Greberg, J. Optimization of truck-loader haulage system in an underground mine: A simulation approach using SimMine. In Proceedings of the 6th International Conference & Exhibition on Mass Mining, Sudbury, ON, Canada, 10–14 June 2012.
18. Khandelwal, M.; Singh, T. Prediction of blast-induced ground vibration using artificial neural network. *Int. J. Rock Mech. Min. Sci.* 2009, 46, 1214–1222. <http://doi.org/10.1016/j.ijrmms.2009.03.004>
19. Khandelwal, M.; Kumar, D.; Yellishetty, M. Application of soft computing to predict blast-induced ground vibration. *Eng. Comput.* 2011, 27, 117–125. <http://doi.org/10.1007/s00366-009-0157-y>
20. Zhongya, Z.; Xiaoguang, J. Prediction of peak velocity of blasting vibration based on artificial neural network optimized by dimensional reduction of FA-MIV. *Math. Probl. Eng.* 2018, 2018, 8473547. <http://doi.org/10.1155/2018/8473547>
21. Lavrenko, S.A.; Shishljannikov, D.I. Performance evaluation of heading-and-winning machines in the conditions of potash mines. *Appl. Sci.* 2021, 11, 3444. <http://doi.org/10.3390/app11083444>
22. Desai, C.; Shaikh, A. Drill wear monitoring using artificial neural network with differential evolution learning. In Proceedings of the 2006 IEEE International Conference Industry Technology, IEEE, Mumbai, India, 15–17 December 2006; pp. 2019–2022. <http://doi.org/10.1109/ICIT.2006.372500>
23. Lashari, S.; Takbiri-Borujeni, A.; Fathi, E.; Sun, T.; Rahmani, R.; Khazaeli, M. Drilling performance monitoring and optimization: A data-driven approach. *J. Pet. Explor. Prod. Technol.* 2019, 9, 2747–2756. <http://doi.org/10.1007/s13202-019-0657-2>
24. Zemenkova, M.Y.; Chizhevskaya, E.L.; Zemenkov, Y.D. Intelligent monitoring of the condition of hydrocarbon pipeline transport facilities using neural network technologies. *J. Min. Inst.* 2022, 258, 933–944. <http://doi.org/10.31897/PMI.2022.105>
25. Filippov, E.V.; Zakharov, L.A.; Martyushev, D.A.; Ponomareva, I.N. Reproduction of reservoir pressure by machine learning methods and study of its influence on the cracks formation process in hydraulic fracturing. *J. Min. Inst.* 2022, 258, 924–932. <http://doi.org/10.31897/PMI.2022.103>
26. Klyuev, R.; Fomenko, O.; Gavrina, O.; Turluev, R.; Marzoev, S. Energy indicators of drilling machines and excavators in mountain territories. *Adv. Intell. Syst. Comput. (EMMFT 2019)* 2021, 1258, 272–281. http://doi.org/10.1007/978-3-030-57450-5_25
27. Sychev, Y.A.; Zimin, R.Y. Improving the quality of electricity in the power supply systems of the mineral resource complex with hybrid filter-compensating devices. *J. Min. Inst.* 2021, 247, 132–140. <http://doi.org/10.31897/PMI.2021.1.14>
28. Shaobo, X.; Xiaosong, H.; Shanwei, Q.; Xiaolin, T.; Kun, L.; Zongke, X.; Brighton, J. Model predictive energy management for plug-in hybrid electric vehicles considering optimal battery depth of discharge. *Energy* 2019, 173, 667–678. <http://doi.org/10.1016/j.energy.2019.02.074>
29. Shuo, Z.; Xiaosong, H.; Shaobo, X.; Ziyu, S.; Lin, H.; Cong, H. Adaptively coordinated optimization of battery ageing and energy management in plug-in hybrid electric buses. *Appl. Energy* 2019, 256, 113891. <http://doi.org/10.1016/j.apenergy.2019.113891>
30. Xuebing, H.; Languang, L.; Yuejiu, Z.; Xuning, F.; Zhe, L.; Jianqiu, L.; Minggao, O. A review on the key issues of the lithium-ion battery degradation among the whole life cycle. *ETransportation* 2019, 1, 100005. <http://doi.org/10.1016/j.etrans.2019.100005>
31. Yanbiao, F.; Zuomin, D. Optimal energy management with balanced fuel economy and battery life for large hybrid electric mining truck. *J. Power Sources* 2020, 454, 227948. <http://doi.org/10.1016/j.jpowsour.2020.227948>

32. Sychev, Y.A.; Kostin, V.N.; Serikov, V.A.; Aladin, M.E. Nonsinusoidal modes in power-supply systems with nonlinear loads and capacitors in mining. *Min. Inf. Anal. Bull. (MIAB)* 2023, 1, 159–179. http://doi.org/10.25018/0236_1493_2023_1_0_159
33. Nikolaev, A.V.; Vöth, S.; Kychkin, A.V. Application of the cybernetic approach to price-dependent demand response for underground mining enterprise electricity consumption. *J. Min. Inst.* 2022, 256, 686. <http://doi.org/10.31897/PMI.2022.33>
34. Klyuev, R.V.; Morgoev, I.D.; Morgoeva, A.D.; Gavrina, O.A.; Martyushev, N.V.; Efremenko, E.A.; Mengxu, Q. Methods of Forecasting Electric Energy Consumption: A Literature Review. *Energies* 2022, 15, 8919. <http://doi.org/10.3390/en15238919>
35. Gundewar, S.K.; Kane, P.V. Condition Monitoring and Fault Diagnosis of Induction Motor. *J. Vib. Eng. Technol.* 2021, 9, 643–674. <http://doi.org/10.1007/s42417-020-00253-y>
36. Zhao, Z.; Li, T.; Wu, J.; Sun, C.; Wang, S.; Yan, R.; Chen, X. Deep learning algorithms for rotating machinery intelligent diagnosis: An open source benchmark study. *ISA Trans.* 2020, 107, 224–255. <http://doi.org/10.1016/j.isatra.2020.08.010>
37. Gangsar, P.; Tiwari, R. Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mech. Syst. Signal Process.* 2020, 144, 106908. <http://doi.org/10.1016/j.ymssp.2020.106908>
38. Soomro, A.A.; Mokhtar, A.A.; Kurnia, J.C.; Lashari, N.; Lu, H.; Sambo, C. Integrity assessment of corroded oil and gas pipelines using machine learning: A systematic review. *Eng. Fail. Anal.* 2022, 131, 105810. <http://doi.org/10.1016/j.engfailanal.2021.105810>
39. Cui, Y.; Kara, S.; Chan, K.C. Manufacturing big data ecosystem: A systematic literature review. *Robot. Comput.-Integr. Manuf.* 2020, 62, 101861. <http://doi.org/10.1016/j.rcim.2019.101861>
40. Kahr, M.; Kovács, G.; Loinig, M.; Brückl, H. Condition Monitoring of Ball Bearings Based on Machine Learning with Synthetically Generated Data. *Sensors* 2022, 22, 2490. <http://doi.org/10.3390/s22072490>
41. Chelmiah, E.T.; McLoone, V.I.; Kavanagh, D.F. Remaining Useful Life Estimation of Rotating Machines through Supervised Learning with Non-Linear Approaches. *Appl. Sci.* 2022, 12, 4136. <http://doi.org/10.3390/app12094136>
42. Bejaoui, I.; Bruneo, D.; Xibilia, M.G. Remaining Useful Life Prediction of Broken Rotor Bar Based on Data-Driven and Degradation Model. *Appl. Sci.* 2021, 11, 7175. <http://doi.org/10.3390/app11167175>
43. Ferreira, C.; Gonçalves, G. Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods. *J. Manuf. Syst.* 2022, 63, 550–562. <http://doi.org/10.1016/j.jmsy.2022.05.010>
44. Lv, H.; Chen, J.; Pan, T.; Zhang, T.; Feng, Y.; Liu, S. Attention mechanism in intelligent fault diagnosis of machinery: A review of technique and application. *Measurement* 2022, 199, 111594. <http://doi.org/10.1016/j.measurement.2022.111594>
45. Kudelina, K.; Vaimann, T.; Rassölkin, A.; Kallaste, A.; Demidova, G.; Karpovich, D. Diagnostic Possibilities of Induction Motor Bearing Currents. In Proceedings of the 2021 XVIII International Scientific Technical Conference Alternating Current Electric Drives (ACED), Ekaterinburg, Russia, 24–27 May 2021; pp. 1–5. <http://doi.org/10.1109/ACED50605.2021.9462298>
46. Merizalde, Y.; Hernández-Callejo, L.; Duque-Perez, O. State of the Art and Trends in the Monitoring, Detection and Diagnosis of Failures in Electric Induction Motors. *Energies* 2017, 10, 1056. <http://doi.org/10.3390/en10071056>
47. Grasso, M.; Chatterton, S.; Pennacchi, P.; Colosimo, B.M. A data-driven method to enhance vibration signal decomposition for rolling bearing fault analysis. *Mech. Syst. Signal Process.* 2016, 81, 126–147. <http://doi.org/10.1016/j.ymssp.2016.02.067>
48. Zhou, X.; Mao, S.; Li, M. A Novel Anti-Noise Fault Diagnosis Approach for Rolling Bearings Based on Convolutional Neural Network Fusing Frequency Domain Feature Matching Algorithm. *Sensors* 2021, 21, 5532. <http://doi.org/10.3390/s21165532>
49. Yakhni, M.F.; Cauet, S.; Sakout, A.; Assoum, H.; Etien, E.; Rambault, L.; El-Gohary, M. Variable speed induction motors' fault detection based on transient motor current signatures analysis: A review. *Mech. Syst. Signal Process.* 2023, 184, 109737. <http://doi.org/10.1016/j.ymssp.2022.109737>
50. Wu, G.; Yan, T.; Yang, G.; Chai, H.; Cao, C. A Review on Rolling Bearing Fault Signal Detection Methods Based on Different Sensors. *Sensors* 2022, 22, 8330. <http://doi.org/10.3390/s2218330>
51. Wang, L.; Liu, Z.; Liu, A.; Tao, F. Artificial intelligence in product lifecycle management. *Int. J. Adv. Manuf. Technol.* 2021, 114, 771–796. <http://doi.org/10.1007/s00170-021-06882-1>
52. Kumar, N.M.; Chand, A.A.; Malvoni, M.; Prasad, K.A.; Mamun, K.A.; Islam, F.R.; Chopra, S.S. Distributed Energy Resources and the Application of AI, IoT, and Blockchain in Smart Grids. *Energies* 2020, 13, 5739. <http://doi.org/10.3390/en13215739>
53. Koteleva, N.; Loseva, E. Development of an Algorithm for Determining Defects in Cast-in-Place Piles Based on the Data Analysis of Low Strain Integrity Testing. *Appl. Sci.* 2022, 12, 10636. <http://doi.org/10.3390/app122010636>
54. Beloglazov, I.I.; Sabinin, D.S.; Nikolaev, M.Y. Modeling the disintegration process for ball mills using dem. *MIAB. Min. Inf. Anal. Bull.* 2022, 6, 268–282. http://doi.org/10.25018/0236_1493_2022_6_0_268
55. Baranov, G.; Nepomuceno, E.; Vaganov, M.; Ostrovskii, V.; Butusov, D. New Spectral Markers for Broken Bars Diagnostics in Induction Motors. *Machines* 2020, 8, 6. <http://doi.org/10.3390/machines8010006>
56. Raja, H.; Kudelina, K.; Asad, B.; Vaimann, T.; Kallaste, A.; Rassölkin, A.; Khang, H.V. Signal Spectrum-Based Machine Learning Approach for Fault Prediction and Maintenance of Electrical Machines. *Energies* 2022, 15, 9507. <http://doi.org/10.3390/en15249507>
57. AlShalalfeh, A.; Shalalfeh, L. Bearing Fault Diagnosis Approach under Data Quality Issues. *Appl. Sci.* 2021, 11, 3289. <http://doi.org/10.3390/app11073289>
58. Wang, Y.; Xiao, Z.; Cao, G. A convolutional neural network method based on Adam optimizer with power-exponential learning rate for bearing fault diagnosis. *J. Vibroeng.* 2022, 24, 666–678. <http://doi.org/10.21595/jve.2022.22271>
59. Ciszewski, T.; Gelman, L.; Ball, A. Novel Nonlinear High Order Technologies for Damage Diagnosis of Complex Assets. *Electronics* 2022, 11, 3885. <http://doi.org/10.3390/electronics11233885>
60. Shabalov, M.Y.; Zhukovskiy, Y.L.; Buldysko, A.D.; Gil, B.; Starshaia, V.V. The influence of technological changes in energy efficiency on the infrastructure deterioration in the energy sector. *Energy Rep.* 2021, 7, 2664–2680. <http://doi.org/10.1016/j.egyr.2021.05.001>
61. Xu, M.; Marangoni, R.D. Vibration analysis of a motor-flexible coupling-rotor system subject to misalignment and unbalance, Part I: Theoretical model and analysis. *J. Sound Vib.* 1994, 176, 663–679. <http://doi.org/10.1006/jsvi.1994.1405>
62. Abouelanouar, B.; Elkihel, A.; Gziri, H. Experimental study on energy consumption in rotating machinery caused by misalignment. *SN Appl. Sci.* 2020, 2, 1215. <http://doi.org/10.1007/s42452-020-3043-2>
63. Choudhary, A.; Goyal, D.; Shimi, S.L.; Akula, A. Condition Monitoring and Fault Diagnosis of Induction Motors: A Review. *Arch. Computat. Methods Eng.* 2019, 26, 1221–1238. <http://doi.org/10.1007/s11831-018-9286-z>

64. Khan, M.A.; Asad, B.; Kudelina, K.; Vaimann, T.; Kallaste, A. The Bearing Faults Detection Methods for Electrical Machines – The State of the Art. *Energies* 2023, 16, 296. <http://doi.org/10.3390/en16010296>
65. Ambrozkiwicz, B.; Litak, G.; Georgiadis, A.; Syta, A.; Meier, N.; Gassner, A. Effect of Radial Clearance on Ball Bearing's Dynamics Using a 2-DOF Model. *Int. J. Simul. Model* 2021, 20, 513–524. <http://doi.org/10.2507/IJSIMM20-3-568>
66. Russell, T.; Sadeghi, F.; Peterson, W.; Aamer, S.; Arya, U. A Novel Test Rig for the Investigation of Ball Bearing Cage Friction. *Tribol. Trans.* 2021, 64, 943–955. <http://doi.org/10.1080/10402004.2021.1953657>
67. Xu, L.; Chatterton, S.; Pennacchi, P. Rolling element bearing diagnosis based on singular value decomposition and composite squared envelope spectrum. *Mech. Syst. Signal Process.* 2021, 148, 107174. <http://doi.org/10.1016/j.ymssp.2020.107174>
68. Golyandina, N.; Korobeynikov, A. Basic Singular Spectrum Analysis and forecasting with R. *Comput. Stat. Data Anal.* 2014, 71, 934–954. <http://doi.org/10.1016/j.csda.2013.04.009>
69. Doynikov, A.N.; Salnikova, M.K.; Kalinin, M.P. Method for predicting non-stationary processes in structurally unstable systems. *Mod. Technol. Syst. Analysis. Model.* 2008, 2, 119–123. (In Russian)
70. Golyandina, N.E. Particularities and commonalities of singular spectrum analysis as a method of time series analysis and signal processing. *WIREs Comput. Stat.* 2020, 12, e1487. <http://doi.org/10.1002/wics.1487>
71. Zhao, X.; Ye, B. Feature frequency extraction algorithm based on the singular value decomposition with changed matrix size and its application in fault diagnosis. *J. Sound Vib.* 2022, 526, 116848. <http://doi.org/10.1016/j.jsv.2022.116848>
72. Guo, M.; Li, W.; Yang, Q.; Zhao, X.; Tang, Y. Amplitude filtering characteristics of singular value decomposition and its application to fault diagnosis of rotating machinery. *Measurement* 2020, 154, 107444. <http://doi.org/10.1016/j.measurement.2019.107444>
73. Zhao, X.; Ye, B. Similarity of signal processing effect between Hankel matrix-based SVD and wavelet transform and its mechanism analysis. *Mech. Syst. Signal Process.* 2009, 23, 1062–1075. <http://doi.org/10.1016/j.ymssp.2008.09.009>
74. Azouzi, K.; Boudinar, A.H.; Aimer, F.A.; Bendiabdellah, A. Use of a combined SVD-Kalman filter approach for induction motor broken rotor bars identification. *J. Microw. Optoelectron. Electromagn. Appl.* 2018, 17, 85–101. <http://doi.org/10.1590/2179-10742018v17i11136>
75. Cong, F.; Chen, J.; Dong, G.; Zhao, F. Short-time matrix series based singular value decomposition for rolling bearing fault diagnosis. *Mech. Syst. Signal Process.* 2013, 34, 218–230. <http://doi.org/10.1016/j.ymssp.2012.06.005>
76. Zhao, H.; Sun, M.; Deng, W.; Yang, X. A New Feature Extraction Method Based on EEMD and Multi-Scale Fuzzy Entropy for Motor Bearing. *Entropy* 2017, 19, 14. <http://doi.org/10.3390/e19010014>
77. Isham, M.F.; Leong, M.S.; Lim, M.H.; Ahmad, Z.A. Variational Mode Decomposition: Mode Determination Method for Rotating Machinery Diagnosis. *J. Vibroeng.* 2018, 20, 2604–2621. <http://doi.org/10.21595/jve.2018.19479>
78. Wang, H.; Li, R.; Tang, G.; Yuan, H.; Zhao, Q.; Cao, X. A Compound Fault Diagnosis for Rolling Bearings Method Based on Blind Source Separation and Ensemble Empirical Mode Decomposition. *PLoS ONE* 2014, 9, e109166. <http://doi.org/10.1371/journal.pone.0109166>
79. SKF. Damage to Rolling Bearings and Their Cause. (In Russian). Available online: https://www.promshop.info/cataloguespdf/reasons_damage_bearings.pdf (accessed on 24 November 2022).
80. Skamyin, A.; Shklyarskiy, Y.; Dobush, I.; Dobush, V.; Sutikno, T.; Jopri, M.H. An assessment of the share contributions of distortion sources for various load parameters. *International. J. Power Electron. Drive Syst. (IJPEDS)* 2022, 13, 950. <http://doi.org/10.11591/ijpeds.v13.i2.pp950-959>
81. Kuzmin, O.V.; Kedrin, V.S. Analysis of the structure of harmonic series of dynamics based on the singular value decomposition algorithm. *Manag. Probl.* 2013, 1, 26–31. (In Russian)
82. Revin, I.; Potemkin, V.A.; Balabanov, N.R.; Nikitin, N.O. Automated machine learning approach for time series classification pipelines using evolutionary optimization. *Knowl.-Based Syst.* 2023, 268, 110483. <http://doi.org/10.1016/j.knosys.2023.110483>
83. Xu, L.; Chatterton, S.; Pennacchi, P.; Liu, C. A Tacholeless Order Tracking Method Based on Inverse Short Time Fourier Transform and Singular Value Decomposition for Bearing Fault Diagnosis. *Sensors* 2020, 20, 6924. <http://doi.org/10.3390/s20236924> <http://www.ncbi.nlm.nih.gov/pubmed/33287373>