

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«РОССИЙСКИЙ ГОСУДАРСТВЕННЫЙ АГРАРНЫЙ УНИВЕРСИТЕТ –
МСХА имени К. А. ТИМИРЯЗЕВА»

На правах рукописи

СТУПИН ОЛЕГ АЛЕКСАНДРОВИЧ

**РАЗРАБОТКА КОМБИНИРОВАННОГО МЕТОДА
ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ НАСОСОВ
СЕЛЬСКОХОЗЯЙСТВЕННОЙ ТЕХНИКИ**

Специальность: 4.3.1. Технологии, машины и оборудование для
агропромышленного комплекса

ДИССЕРТАЦИЯ

на соискание ученой степени

кандидата технических наук

Научный руководитель

доктор технических наук,

профессор

Апатенко Алексей Сергеевич

Москва – 2026

Содержание

ВВЕДЕНИЕ.....	4
ГЛАВА 1. ТЕОРЕТИКО-МЕТОДОЛОГИЧЕСКИЕ ПРЕДПОСЫЛКИ РАЗВИТИЯ ДИАГНОСТИРОВАНИЯ ТЕХНИЧЕСКИХ СИСТЕМ.....	12
1.1 Технологии и аналитический инструментарий диагностирования технических систем.....	12
1.2 Анализ методов отбора диагностических признаков для обнаружения неисправностей технических систем	32
1.3 Анализ методов обнаружения неисправностей технических систем	43
Вывод по первой главе	63
ГЛАВА 2. АНАЛИЗ МЕТОДОВ ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ СИСТЕМ.....	65
2.1 Интеллектуальные методы вибродиагностирования гидравлических систем машин и оборудования на основе сигналов	65
2.2 Анализ методов вибродиагностирования неисправностей гидравлических насосов машин и оборудования.....	73
Вывод по второй главе	85
ГЛАВА 3. РАЗРАБОТКА КОМБИНИРОВАННОГО МЕТОДА ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ НАСОСОВ СЕЛЬСКОХОЗЯЙСТВЕННОЙ ТЕХНИКИ	86
3.1 Разработка алгоритма комбинированного метода вибродиагностирования гидравлических насосов сельскохозяйственной техники.....	86
3.2 Анализ результатов исследований.....	96
Выводы по третьей главе	116
ГЛАВА 4. РАЗРАБОТКА ПРОГРАММНОГО КОМПЛЕКСА АВТОМАТИЗИРОВАННОГО ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ НАСОСОВ СЕЛЬСКОХОЗЯЙСТВЕННОЙ ТЕХНИКИ.....	118

4.1 Архитектура программного комплекса вибродиагностирования гидравлических насосов сельскохозяйственной техники	118
4.2 Вычислительное ядро программного комплекса вибродиагностирования гидравлических насосов сельскохозяйственной техники.....	136
4.3 Методика тестирования разработанного программного комплекса вибродиагностирования гидравлических насосов сельскохозяйственной техники.....	138
4.4 Анализ точности программного комплекса вибродиагностирования гидравлических насосов сельскохозяйственной техники.....	139
4.5 Перспективы развития программы вибродиагностирования гидравлических насосов сельскохозяйственной техники	148
Выводы по четвертой главе	148
ГЛАВА 5. ЭКОНОМИЧЕСКОЕ ОБОСНОВАНИЕ ВНЕДРЕНИЯ РАЗРАБОТАННОГО КОМБИНИРОВАННОГО МЕТОДА ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ НАСОСОВ СЕЛЬСКОХОЗЯЙСТВЕННОЙ ТЕХНИКИ	151
Вывод по пятой главе	153
ЗАКЛЮЧЕНИЕ	154
СПИСОК ЛИТЕРАТУРЫ	157
ПРИЛОЖЕНИЯ.....	173

ВВЕДЕНИЕ

Актуальность темы исследования.

В соответствии с положениями «Стратегии развития сельского хозяйства Российской Федерации на период до 2030 года» (утвержденной распоряжением Правительства РФ от 8 сентября 2022 г. № 2567-р (с изменениями на 19 декабря 2025 года)) и задачами, определенными в рамках реализации Государственной программы развития сельского хозяйства, ключевым направлением является обеспечение технологической независимости и конкурентоспособности агропромышленного комплекса. Достижение этих стратегических целей напрямую связано с поддержанием высокого уровня технической готовности и надежности сельскохозяйственной техники. В современной сельскохозяйственной технике для управления навесным оборудованием, рулевого управления, привода рабочих органов и их позиционирования широко применяются гидравлические системы что обусловлено высокой удельной мощностью, компактностью и точностью управления. Работоспособность гидросистемы является важным аспектом для обеспечения непрерывности технологического процесса. Согласно данным ФГБНУ «Росинформагротех», 15% отказов сельскохозяйственной техники связано с гидравлическими системами, при этом отказы распределяются следующим образом: около 35% приходится на рукава высокого давления, 25% – на гидронасосы, 20% – на распределители, 10% – на гидроцилиндры и ещё 10% – на прочие элементы.

Таким образом, гидравлические насосы, как одни из наиболее нагруженных узлов сельскохозяйственной техники, работают в условиях интенсивных динамических нагрузок и переменных режимов, что обуславливает прогрессирующее ухудшение их технического состояния и является частой причиной внезапных отказов.

Отказ гидравлического насоса в периоды выполнения ответственных агротехнологических операций ведет к остановке машины и как следствие к прямым экономическим потерям и срыву установленных сроков работ.

Диагностирование гидравлических насосов в режиме онлайн позволяет оценить и контролировать их техническое состояние с целью выявления дефектов на ранней стадии неисправностей и обеспечения своевременного и эффективного технического обслуживания и ремонта.

Одним из перспективных методов диагностирования гидравлических насосов является вибрационный. Он позволяет определять техническое состояние элементов (деталей) по параметрам вибраций. Основными преимуществами выбранного метода являются: возможность производить диагностирование без разборки агрегата, высокая скорость определения неисправностей. Основным недостатком вибродиагностирования является высокая сложность обработки сигналов и выявления полезной, диагностической информации на фоне характерных для гидравлических насосов вибрационных процессов.

Существующие методы вибродиагностирования часто недостаточно эффективны в нестационарных режимах, характерных для эксплуатации сельскохозяйственной техники. В этой связи разработка автоматизированного метода, направленного на выявление дефектов, снижающих объемный коэффициент полезного действия гидравлического насоса, представляет актуальную научно-практическую задачу. Это формирует основу для перехода от планово-предупредительного обслуживания к обслуживанию по фактическому состоянию.

Степень разработанности темы исследования.

Изучению вопросов диагностирования гидравлических систем и оборудования посвящены работы: Аллилуева В.А., Артемьева Ю.Н., Бельских И.Б., Буклагина Д.С., Гальперина А.Р., Гринчара Н.Г., Дидманидзе О.Н., Зорина В.А., Кальбуса Г.Л., Колчина А.В., Кривенко П.М., Михлина В.М., Павлова Ю.Н., Петрищева Н.А., Пильщикова Н.А., Севрюгиной Н.С., Северного А.Э., Сивцова В.Н., Скибневского К.Ю., Черноиванова В.И., Черепанова С.С. При этом изучению вибродиагностирования гидравлических систем и оборудования посвящены работы: Баркова А.В., Бишоп А.Я.,

Герасимова В.С., Денисова В.С., Костюкова В.Н., Макуева В.Б., Павлова Б.В., Рубичева Н.А., Ширмана А.Р., Чечета В.А., Cheng J., Choy F.K., Deng X., Li Z., Unal M., Zheng H. и других.

При этом проведенный анализ публикаций отечественных и зарубежных авторов по вибродиагностированию технического состояния оборудования выявил недостаточное внимание к исследованиям и разработкам таких важных составляющих системы, как методы выделения и отбора признаков дефектов на этапе предварительной обработки сигналов и методов выявления и диагностирования неисправностей гидравлических насосов. Недостаточная разработанность этих вопросов значительно снижает качество информации, получаемой в процессе мониторинга для принятия решений по техническому обслуживанию гидравлических насосов.

Актуальность проблемы, её недостаточная научная разработка определили цель, задачи, объект и предмет диссертационного исследования.

Цель исследования – повышение эффективности эксплуатации сельскохозяйственной техники путем совершенствования методов вибродиагностирования гидравлических насосов.

Для достижения поставленной цели необходимо решение следующих **задач**:

1. Провести системный анализ, обзор и синтез современных методов вибродиагностирования технических систем.
2. Разработать адаптивный алгоритм вибродиагностирования гидравлических насосов сельскохозяйственной техники, основанный на интеллектуальном отборе информативных признаков из вибрационного сигнала.
3. Разработать и экспериментально обосновать комбинированный метод вибродиагностирования для оценки технического состояния гидравлических насосов.
4. Разработать программный комплекс для автоматизированного вибродиагностирования с реализацией адаптивных алгоритмов анализа

сигналов и интеллектуальной классификации дефектов гидравлических насосов.

5. Провести оценку точности разработанного программного комплекса для автоматизированного вибродиагностирования гидравлических насосов, установить и обосновать диагностические пороги для ключевых дефектов, дать рекомендации по использованию полученных результатов на предприятиях технического сервиса сельскохозяйственной техники АПК России.

6. Обосновать экономическую эффективность внедрения разработанного программного комплекса вибродиагностирования гидравлических насосов при эксплуатации сельскохозяйственной техники АПК России.

Объект исследований – интеллектуальные методы диагностирования гидравлических насосов сельскохозяйственной техники.

Предмет исследований – информационные свойства и диагностические признаки вибрационных сигналов, генерируемые гидравлическим насосом, для последующего их использования при определении их технического состояния.

Научная новизна состоит в получении математической зависимости комбинированного индекса дефектности от ключевых диагностических параметров, который позволяет комплексно оценивать техническое состояние насоса, а также в разработке комбинированного метода вибродиагностирования гидравлических насосов, основанного на совместном использовании спектрального анализа (СПМ), алгоритма J48 для отбора признаков и нечёткого вывода для классификации.

Теоретическая и практическая значимость работы.

Теоретическая значимость заключается в развитии методов вибродиагностирования гидравлических насосов за счёт комплексного использования энергетического, статистического и спектрального анализа сигналов. Разработанный комбинированный подход расширяет теоретические

представления о выделении информативных признаков и классификации дефектов гидравлических насосов в условиях нестационарных режимов работы сельскохозяйственной техники.

Практическая значимость заключается в создании программного комплекса для автоматизированного вибродиагностирования гидравлических насосов, который реализует разработанный комбинированный метод, и может быть использован при эксплуатации сельскохозяйственной техники и на предприятиях технического сервиса АПК России.

Методология и методы исследования.

При решении поставленных задач применялся системный подход. Использовались методы обработки сигналов: быстрое преобразование Фурье, вейвлет-анализ, расчёт спектральной плотности мощности; методы анализа данных и снижения размерности: анализ главных компонент и независимых компонент; методы классификации: деревья решений (J48) и нечёткий логический вывод.

Основные положения, выносимые на защиту:

1. Метод вибродиагностирования гидравлических насосов, основанный на использовании анализа спектральной плотности мощности вибросигнала для помехоустойчивого выделения признаков, алгоритма деревьев решений J48 для автоматизированного отбора информативных диагностических параметров и генерации логических правил, и нечёткого логического вывода для интерпретируемой классификации технических состояний, обеспечивающий достоверное распознавание дефектов в условиях нестационарных режимов работы.

2. Программный комплекс для автоматизированного вибродиагностирования, реализующий разработанный комбинированный метод и обеспечивающий обработку сигналов – от первичного сбора данных до формирования диагностического заключения с оценкой вероятности дефектов, интегрируемая в действующие процессы технического обслуживания сельскохозяйственной техники.

Степень достоверности и апробация результатов.

Исследования проводились с использованием апробированного инструментального и программного обеспечения для проведения экспериментов, использовались современные методы математической обработки экспериментальных данных.

Диссертационное исследование выполнялась в рамках программы «Студенческий-стартап 2022» при поддержке Фонда Содействия Инновациям и тематического плана выполнения научно-исследовательских работ ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева по заказу Минсельхоза России за счет бюджетных средств в 2023 году.

По результатам проведенных исследований разработаны: программный комплекс для анализа шестеренных гидравлических насосов VibraPump Analyzer (свидетельство о государственной регистрации для ЭВМ № 2025685795); программный комплекс, адаптированный под аксиально-поршневые насосы AxialVibeAnalyst (свидетельство № 2025684170); интерактивные тренажеры диагностирования шестеренных, пластинчатых и радиально-поршневых насосов (свидетельства о государственной регистрации для ЭВМ №2025689770, №2025690844 и №2025695365).

Соответствие диссертации научной специальности. Диссертация соответствует паспорту специальности ВАК 4.3.1. Технологии, машины и оборудование для агропромышленного комплекса (технические науки, сельскохозяйственные науки), в части п.п.:

4. Механизированные, автоматизированные и роботизированные технологии и технические средства для агропромышленного комплекса.

5. Мобильные и стационарные энергетические средства, машины, агрегаты, рабочие органы и исполнительные механизмы.

12. Цифровые интеллектуальные технологии, автоматизированные и роботизированные технические средства для агропромышленного комплекса.

20. Методы и технические средства обеспечения надежности, долговечности, диагностики, технического сервиса, технологии упрочнения, ремонта и восстановления машин и оборудования.

Апробация работы.

Основные результаты научной работы обсуждались и получили положительную оценку в профессиональной среде на семинарах, круглых столах и научно-практических конференциях: Международная научная конференция профессорско-преподавательского состава, посвященная 155-летию РГАУ–МСХА имени К.А. Тимирязева Москва, 02–04 декабря 2020 года; Наземные транспортно-технологические комплексы и средства Тюмень, 08 февраля 2021 года; СЕМИНАР «Чтения академика В. Н. Болтинского» Москва, 25–26 января 2022 года; 26-Я Московская Международная межвузовская научно-техническая конференция студентов, магистрантов, аспирантов и молодых ученых "Подъемно-транспортные, строительные, дорожные, путевые, мелиоративные машины и робототехнические комплексы" Москва, 12–13 мая 2022 года; Инновации в природообустройстве и защите в чрезвычайных ситуациях Саратов, 27–28 апреля 2022 года; Чтения академика В. Н. Болтинского Москва, 25–26 января 2023 года; Инновации в природообустройстве и защите в чрезвычайных ситуациях, Саратов, 16–17 мая 2023 года; Подъемно-транспортные, строительные, дорожные, путевые, мелиоративные машины и робототехнические комплексы, Москва, 26–27 апреля 2023 года; Транспортные и транспортно-технологические системы, Тюмень, 13–14 апреля 2023 года; Будущее науки – 2024, Курск, 18–19 апреля 2024 года.

Публикации результатов исследований.

Основные положения и результаты диссертационного исследования изложены в 17 научных публикациях, из которых 4 статьи опубликованы в изданиях, рекомендованных ВАК РФ, выпущены 2 учебных пособия и 1 монография, получено 5 свидетельств о государственной регистрации программ для ЭВМ.

Структура и объем диссертации.

Диссертация состоит из введения, пяти глав, заключения, списка литературы и приложения. Работа изложена на 209 страницах, включает 61 рисунок и 16 таблиц. Список литературы содержит 144 источника.

ГЛАВА 1. ТЕОРЕТИКО-МЕТОДОЛОГИЧЕСКИЕ ПРЕДПОСЫЛКИ РАЗВИТИЯ ДИАГНОСТИРОВАНИЯ ТЕХНИЧЕСКИХ СИСТЕМ

1.1 Технологии и аналитический инструментарий диагностирования технических систем

С развитием современной агропродовольственной системы и аграрного производства сельскохозяйственная техника получает всестороннее распространение. Вместе с этим растёт сложность этой техники, поэтому увеличивается и вероятность её выхода из строя, что актуализирует задачи повышения эксплуатационной надёжности и эффективности ремонтно-технического обеспечения [1]. Поскольку сельскохозяйственная техника часто находится в пыльной и влажной средах, происходит загрязнение, в процессе работы часто возникают перегрузки, места хранения техники подвергаются воздействию погодных условий, что приводит к возникновению неисправностей, отказов и раннего выхода из строя технических систем. В современных условиях для повышения производительности труда в аграрном секторе необходимо учитывать новые технико-экономические требования, такие как высокая степень механизации и точное выполнение агротехнических работ в установленные сроки [2]. Для эффективной эксплуатации сельскохозяйственной техники необходимо совершенствовать подходы и системы диагностирования, технического обслуживания и ремонта [3].

Гидравлические системы широко используются в современной сельскохозяйственной технике что обусловлено их высокой удельной мощностью, компактностью и точностью управления. Гидросистема часто является основным компонентом технических систем, таких как системы управления и передачи мощности, которые обычно эксплуатируются в полевых условиях.

В этих условиях дорогостоящие мероприятия по ремонту сельскохозяйственной техники следует проводить на основании достоверных данных о его техническом состоянии.

Повышение сложности и функциональности современных сельскохозяйственной техники сопровождается ростом требований к ее надежности и эффективности эксплуатации. В этих условиях традиционные методы планово-предупредительного обслуживания оказываются недостаточно эффективными. Развитие методов анализа данных и средств диагностирования создает возможность для перехода к интеллектуальному мониторингу технического состояния в режиме реального времени [4]. Помимо обнаружения неисправности, повреждения или описания состояния объекта, диагностические устройства могут идентифицировать, локализовать и классифицировать неисправности и отказы объекта [5].

Общая эволюция концепций систем диагностирования, отражающая этот технологический переход, представлена на рисунке 1.1.



Рисунок 1.1 – Эволюция концепций систем диагностирования

Концепция системы обслуживания по состоянию (СОС) ориентирована на данные режима работы для определения состояния машин и механизмов и, следовательно, его текущего состояния неисправность / отказ, которое может быть использовано для планирования требуемого ремонта и предварительного технического обслуживания, основные требования для применения этой концепции для диагностирования сельскохозяйственной техники проанализированы в работе [6]. Управление техническим состоянием (УТС) относится конкретно к фазе или этапу, связанному с предсказанием будущего поведения, в том числе – остаточного ресурса, с точки зрения текущего

рабочего состояния и планирования необходимых действий по ТО для поддержания работоспособности системы.

В общем случае, систему обслуживания по состоянию можно рассматривать как метод, используемый для уменьшения неопределённости работ по ТО, и осуществляющийся в соответствии с требованиями, определяемыми состоянием оборудования [7]. Следовательно, эта система позволяет выявлять и решать проблемы заранее до возникновения неисправностей.

Концепция системы прогнозирования и управления техническим состоянием [4] сформировалась сравнительно недавно. Принимая во внимание, что СОС и МЦК сосредоточены на мониторинге систем, УТС представляет более интегрированный подход, направленный на обеспечение руководящих принципов при управлении работоспособностью системы. Следовательно, эта концепция осуществляет управление жизненным циклом, с акцентом на предсказуемость (т.е. прогностику) отказов и ТО. Это, как правило, достигается за счёт применения удалённых диагностических систем [8]

При анализе сходства и различия между системами мониторинга оборудования были выделены следующие аспекты (рисунок 1.2).

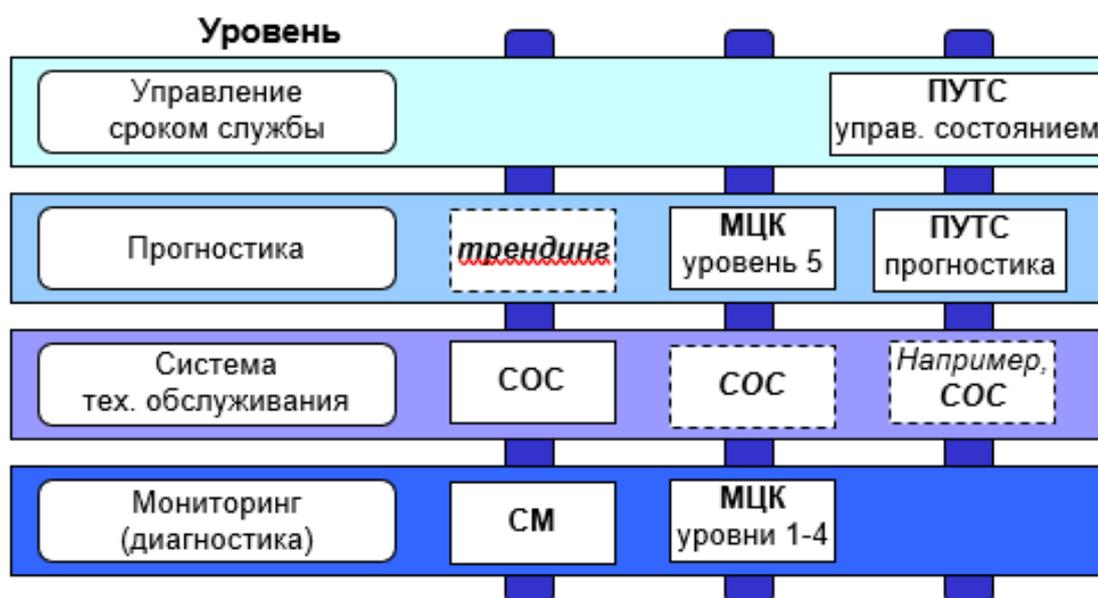


Рисунок 1.2 – Связь между системами СОС, МЦК и УТС.

Подходы в системе контроля состояния и мониторинге целостности конструкции очень похожи, так как обе концепции ищут характеристики, являющиеся репрезентативными для повреждения или износа системы. Тем не менее, есть некоторые различия:

- Система контроля состояния тесно связана с системой обслуживания по состоянию, из этого следует, что результаты мониторинга непосредственно применяются для руководства деятельностью по ТО. В мониторинге целостности конструкции акцент полностью на мониторинге и выполняется без явной связи с мероприятиями по ТО.

- Однако, в обеих системах одним из наиболее часто применяемых методов является мониторинг вибраций, но подходы различаются следующими способами:

- Система контроля в основном применяется к вращающимся или совершающим возвратно-поступательное движение системам, где основным источником вибрации является сама система. Повреждение или деградация диагностируется путём обнаружения изменений в этом источнике, например, неисправности подшипника, которые вводят в систему дополнительные вибрации.

- Мониторинг целостности конструкции в основном применяется для нагруженных или передающих структур, приводимых в действие только с помощью их окружающей среды (ветер, волны). Методы МЦК сосредоточены на измерении (изменения) в реакции системы или структуры и относящиеся к тем, в которых присутствует повреждение.

- Методики размещения датчиков вибрации также различаются. В системе контроля датчик, как правило, размещают за пределами элемента контролируемой системы, в то время как в системе мониторинга целостности конструкции сенсор обычно расположен на (или даже интегрирован в) контролируемой системе.

Обеспечение системного подхода в принятии решений по диагностированию технического состояния оборудования должно быть поддержано исследованиями по обнаружению неисправностей.

При рассмотрении систем обслуживания по состоянию, мониторинга целостности конструкции, прогностики и управления техническим состоянием как отдельных систем, их цели и подходы могут быть согласованы для достижения интегрированной стратегии по улучшению управления сроком службы любой технической системы.

Неразрушающие методы контроля и диагностики. Анализ неразрушающих методов контроля и диагностирования показывает, что контроль оборудования должен носить комплексный характер. Применение одного метода не обеспечивает необходимой надёжности, поэтому необходимо использовать несколько методов. Совокупное использование нескольких методов одновременно позволяет своевременно получать информацию о состоянии оборудования и выявлять дефекты на ранних стадиях их развития. При этом среди неразрушающих методов наибольшей информативностью обладает метод вибрационного диагностирования, так как вибрационный сигнал чувствителен к изменению состояния технических систем [9].

Вибродиагностирование является перспективным методом оценки технического состояния машин. Вибродиагностирование вращающихся машин и механизмов (рисунок 1.3) проводят для определения технического состояния подшипников качения и скольжения, шестеренных и поршневых гидронасосов, двигателей, поршневых, винтовых и пластинчатых компрессоров, нарушенных и неукрепленных фундаментов и др. Каждая машина имеет вибрации, но они должны быть в пределах определенных норм, установленных в соответствующих стандартах и технических условиях [10].

При вибродиагностировании измеряются вибрации и выявляются различные виды неисправностей при работе технических систем, а именно: дисбаланс, не соосность между валами, наличие зазоров, анализ подшипников

качения и скольжения, анализ шестерен, ремня и других зубчатых передач, анализ состояния электрических машин и так далее (рисунок 1.4). Измеряется абсолютная вибрация – т.е. эффективное значение скорости вибрации – среднеквадратичное значение в [мм/с], а также, при необходимости, виброускорение или виброперемещение измеряемой позиции [11].

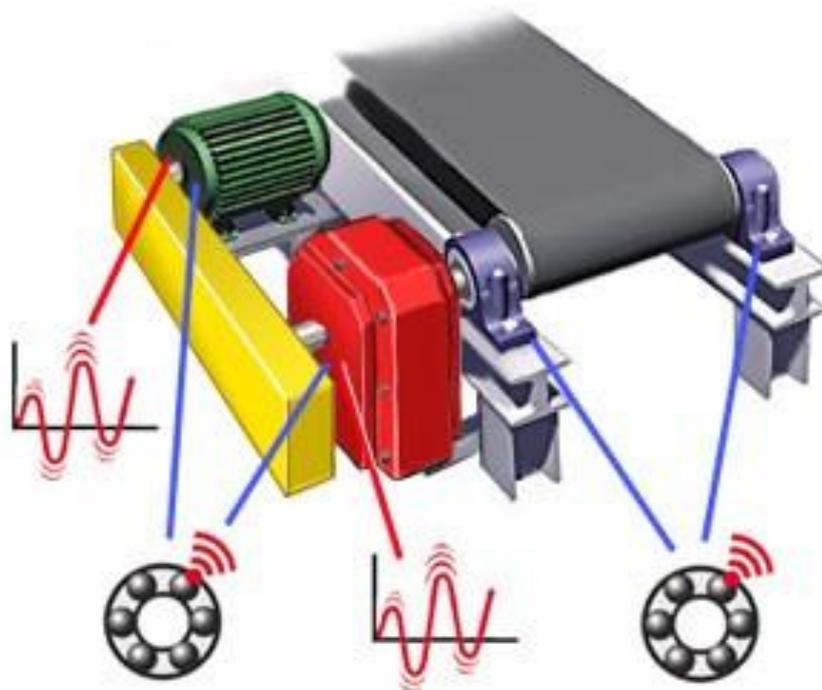


Рисунок 1.3 – Вибродиагностирование вращающихся машин и механизмов

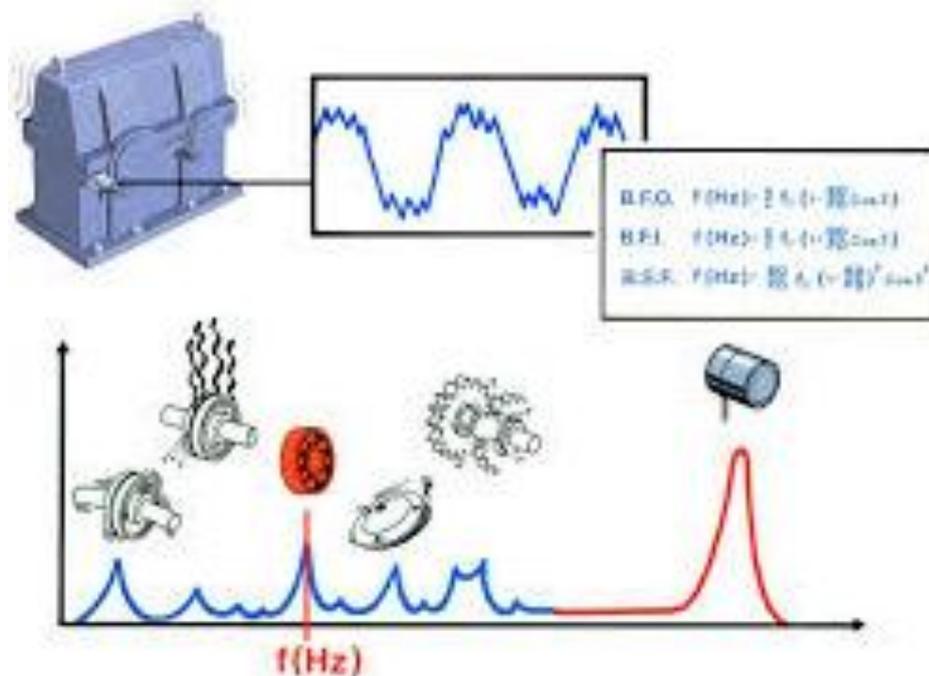


Рисунок 1.4 – Измерение вибрации методами вибродиагностирования

С помощью анализа вибрации может выполняться непрерывный мониторинг и детальный анализ состояния технических систем. Признаки неисправностей часто проявляются в вибрации или изменении картины колебаний. Вибрационный анализ обеспечивает мощный диагностический инструмент поиска и устранения неисправностей. Контроль под нагрузкой может осуществляться, в основном, следующими тремя способами.

(1) Измерения периодического поля переносной аппаратурой. Этот метод обеспечивает информацию о долговременных изменениях в состоянии оборудования. Портативные инструменты работают с высоким коэффициентом нагрузки и часто могут обслуживаться одним человеком.

(2) Непрерывный мониторинг со стационарными инструментами применяется.

(3) Сигнатурный анализ: научный сбор информации, сигналы или сигнатуры, диагностирование и обнаружение неисправностей путём анализа этих сигнатур, на основе знаний ранее полученных в этой области, и оценка по серьёзности сбоев для принятия решений, всё вместе взятое называется сигнатурным анализом.

Сигналы вибрации являются наиболее универсальными параметрами в методах диагностирования состояния оборудования. Контроль периодических колебаний показывает наличие или предпосылки неисправности. Анализ сигнатур вибрации идентифицирует, какая часть системы неисправна и почему.

Таким образом, проведенные исследования технологий и методов обнаружения неисправностей оборудования, позволяют сделать вывод о том, что выбор наиболее подходящих технологии и метода для конкретной технической системы может быть обоснован только с учётом факторов как испытываемого оборудования, его нагрузки, типа дефекта, так и условий окружающей среды.

В основе вибродиагностирования лежит анализ вибрационного сигнала, несущего информацию о техническом состоянии оборудования. В работах [12,

13] данный сигнал рассматривается в более широком контексте, однако в практике непосредственных измерений чаще исследуется именно вибрационная составляющая. Регистрируемый на практике сигнал вибрации обладает сложной структурой, что затрудняет его прямой анализ. Ключевым методом обработки является частотная фильтрация: выделение из исходного широкополосного сигнала определённого информативного частотного диапазона с помощью полосовых фильтров. Эта процедура позволяет преобразовать сложный сигнал в форму, пригодную для последующего анализа и выявления признаков дефектов. Общая схема организации процесса контроля состояния машин на основе вибрационных измерений представлена на рисунке 1.5.



Рисунок 1.5 – Общая схема процесса вибродиагностирования

Ключевой и наиболее сложной проблемой при создании диагностических методик выступает задача идентификации и классификация информативных признаков дефектов из вибрационного сигнала. Эти признаки формируют основу для построения эталонных моделей исправного и дефектного состояний и являются критериями для классификации текущего технического состояния объекта. Сложность данной задачи обусловлена зависимостью вибрационных параметров от множества эксплуатационных факторов, а также трудностью отделения сигнала, порожденного дефектом, от общей вибрационной картины, что отмечается в качестве одной из основных проблем в области вибродиагностирования [14].

Процедура обработки измерительных данных, регламентируемая стандартами (ГОСТ, ISO), включает последовательное выполнение трех основных этапов: сбор первичной информации, фильтрацию помех и сигналов, не несущих диагностической ценности, а также преобразование данных в форму, пригодную для последующего анализа и постановки диагноза [14-17].

Общая схема автоматизированного процесса диагностирования, построенного на применении интеллектуальных методов анализа данных, приведена на рисунке 1.6.



Рисунок 1.6 – Схема процесса интеллектуального диагностирования

Первым этапом процесса является регистрация вибрационного сигнала контролируемого механизма посредством датчика. Последующая предварительная обработка полученных данных, включающая операции фильтрации и нормирования, нацелена на снижение размерности исходного массива информации и выделение значимых диагностических компонент. Эта необходимость обусловлена изначально сложной природой регистрируемых сигналов, которым свойственны нелинейность, неоднородность и высокая степень рассеяния. Корректно выполненная предобработка является ключевым условием для повышения точности и надежности последующего диагностирования.

Эффективность диагностирования технических систем в значительной степени зависит от того, насколько эффективно извлекаются и отбираются информативные признаки из обработанного сигнала [18]. При этом многие аналитические методы, при соответствующей адаптации, обладают универсальностью и могут быть последовательно применены на разных этапах

диагностирования: от формирования признакового пространства до непосредственного обнаружения и классификации дефектов.

Классические методы, в том числе спектральный анализ, средние значения временной области, детектирование огибающей и т.д., являются неэффективными для выделения признаков нестационарных сигналов [19-21]. Это происходит потому, что большинство традиционных методов основано на предположении о стационарном характере сигналов вибрации [19]. В этой связи в анализ нестационарных сигналов вводятся современные технологии, в том числе такие, как распределение Вигнера-Вилле (РВВ), метод эмпирической модовой декомпозиции (ЭМД) [22] и вейвлет-преобразования (ВП). Эти методы могут легко обрабатывать большое количество переменных и являются эффективными при обнаружении неисправностей. Unal и соавт. [23] предложили несколько методов выделения признаков с помощью анализа огибающей, поддерживаемого преобразованием Гильберта и быстрым преобразованием Фурье.

Исходные характеристики неисправности, полученные при современных методах обработки сигналов, содержат определённую избыточность. Если использовать такие сигналы для выявления рабочего состояния технических систем скорость обнаружения неисправностей может быть низкой. Следовательно, уже на этапе первичной обработки данных необходимо использовать методы интеллектуального анализа данных, чтобы устранить ненужные признаки до постановки диагноза. Проблема заключается в сложности определения наиболее отличительных особенностей, то есть необходимо произвести отбор признаков неисправности. Например, один из наиболее популярных методов интеллектуального анализа данных – анализ главных компонент (АГК) и его производные алгоритмы, был обоснован как полезный инструмент для выделения и отбора признаков [24].

Методы обработки вибросигналов можно структурировать в формате первичной обработки данных, включающем последовательно методы

выделения признаков и методы отбора признаков (будут рассмотрены в п. 2.3.).

Методы извлечения диагностических признаков классифицируются в соответствии с областью анализа исходного сигнала: временной, частотной и частотно-временной. Так, в рамках временного подхода применяется статистический анализ, параметрами которого являются среднее значение, стандартное отклонение, среднеквадратичное значение (СКЗ), коэффициенты асимметрии и эксцесса, а также максимальное, минимальное значения и пик-фактор. Однако для эффективного диагностирования, как правило, не требуется использование всего набора признаков [25]. Их диагностическая значимость неравнозначна: одни несут существенную информацию о дефекте, в то время как другие малопредставительны. Таким образом, ключевой задачей становится корректный отбор наиболее информативных признаков, что непосредственно влияет на точность и надёжность всего процесса диагностирования неисправностей.

Рассмотрим состав и особенности каждой из трёх групп методов выделения признаков неисправностей.

Анализ сигналов вибрации во временной области чаще всего реализуется в виде анализа формы сигнала, анализа плотности распределения сигнала или анализа затухающих колебаний системы.

Методы анализа во временной области относятся к числу наиболее ранних подходов к извлечению признаков, первоначально разработанных для диагностики подшипников качения. Их принцип действия основан на непосредственной обработке временной реализации волнового процесса. Исторически отправной точкой послужило эмпирическое наблюдение, что подшипники с повреждениями демонстрируют существенно больший размах вибрации (от пика до пика) по сравнению с исправными аналогами [26]. К ключевым достоинствам этих методов относят вычислительную простоту, возможность прямой обработки сигнала и независимость результатов от скорости вращения вала.

Однако данный подход, как правило, обладает низкой чувствительностью к зарождающимся дефектам и повреждениям. К числу наиболее распространенных параметров, оцениваемых во временной области, относятся общий среднеквадратичный уровень (СКЗ) и пик-фактор:

$$\text{СКЗ} = \sqrt{\frac{1}{N} \sum_{k=1}^N x_k^2} \quad \text{пик-фактор} = \frac{\max(\text{abs}(x))}{\text{СКЗ}}, \quad (1.1)$$

где x – сигнал, полученный составленный N элементами.

Среднеквадратичное значение характеризует общий уровень вибрации и обычно возрастает лишь на поздних стадиях развития дефекта, что ограничивает его чувствительность к зарождающимся повреждениям. Более динамичным индикатором может служить параметр Дельта СКЗ, представляющий собой разность между последовательными значениями СКЗ. В отличие от него, пик-фактор, учитывающий импульсную составляющую вибрации, способен обеспечить более раннее обнаружение неисправности. Для исправного подшипника его величина обычно близка к 5, а отклонение от этого значения может свидетельствовать о наличии дефекта. Важно отметить, что хотя пик-фактор является эффективным индикатором локальных дефектов, его значение может снижаться по мере их развития из-за общего роста вибрации, описываемого параметром СКЗ.

Для выявления дефектов также предлагалось использовать статистические характеристики, такие как функция плотности вероятности. Однако анализ полных кривых распределения часто оказывается избыточным, и более информативным подходом становится исследование статистических моментов данных, которые определяются следующим образом:

$$M_x = \int_{-\infty}^{+\infty} x^n P(x) dx \quad n = 1, 2, \dots, m, \quad (1.2)$$

Где $P(x)$ – являющейся функцией плотности вероятности с мгновенной амплитудой x .

Наименьшей диагностической значимостью обладают первый и второй статистические моменты, известные как среднее значение и дисперсия. Более информативными для обнаружения дефектов считаются нормированные третий и четвёртый моменты – асимметрия и эксцесс, которые особенно полезны при оценке технического состояния оборудования. Для дискретного сигнала их выражения определяются следующим образом:

$$\text{асимметрия} = \frac{\frac{1}{N} \sum_{k=1}^N (x_k - \bar{x})^3}{\left(\frac{1}{N} \sum_{k=1}^N (x_k - \bar{x})^2 \right)^{\frac{3}{2}}} \quad \text{эксцесс} = \frac{\frac{1}{N} \sum_{k=1}^N (x_k - \bar{x})^4}{\left(\frac{1}{N} \sum_{k=1}^N (x_k - \bar{x})^2 \right)^2}, \quad (1.3)$$

где \bar{x} – представляет собой среднее значение сигнала x .

Значение эксцесса для неповрежденного подшипника, с распределением Гаусса близко к 3 и поэтому большее значение эксцесса уже можно рассматривать как признак зарождающегося повреждения.

Усреднённое синхронизированное время (УСВ) – метод анализа во временной области довольно часто применяют для раннего обнаружения отказа шестерённых передач [27]. Сигнал усредненного синхронизированного времени получается путём синхронизации дискретизации по времени сигнала вибрации при вращении конкретной шестерни и последующей оценке среднего ансамбля на протяжении множества оборотов с началом каждого кадра в одном и том же угловом расположении [28].

Другим подходом, связанным с анализом во временной области, является применение моделей временного ряда для данных о форме сигнала [27]. Основная идея состоит в том, чтобы соответствовать данным о форме сигнала в параметрической модели временных рядов и извлекать признаки, основанные на этой параметрической модели. Два примера так называемых авторегрессионной (АР) и авторегрессионной моделей скользящего среднего (АРМСС). Общая АРМСС модель порядка p и q задаётся

$$x_t = a_1 x_{t-1} + \dots + a_p x_{t-p} + \varepsilon_t - b_1 \varepsilon_{t-1} - \dots - b_q \varepsilon_{t-q}, \quad (1.4)$$

где x – представляет собой колебательный сигнал, a_i и b_i являются коэффициентами модели;

ε – нормальное распределение.

Авторегрессионная (АР) модель порядка p является частным случаем модели авторегрессии–скользящего среднего при нулевом порядке скользящего среднего, при $q = 0$. Процедура её построения включает оценку порядка модели, определяющего количество предыдущих отсчётов, необходимых для адекватного описания вибрационного сигнала, оценку соответствующих коэффициентов и последующую проверку адекватности полученной модели. Данный тип моделей применяется для анализа вибрационных сигналов, в частности, когда диагностические признаки формируются на основе оцененных коэффициентов модели. Такое применение продемонстрировано в работе [29], где проведено экспериментальное сравнение трех различных методик АР-моделирования и оценена их диагностическая эффективность при анализе временных рядов вибрации для идентификации ряда искусственно созданных дефектов подшипников качения. Другое практическое применение АР-модели, представленное в [30], основано на использовании обратного фильтра: на первом этапе по сигналу исправной системы синтезируется обратный фильтр, который затем применяется к анализируемому сигналу. Моделирование и обработка реальных данных показывают, что подобный обратный фильтр на основе АР-модели способен усиливать импульсную составляющую сигнала, связанную с дефектом.

К основным преимуществам авторегрессионной (АР) модели относятся её простота, вычислительная эффективность и умеренные требования к реализации. Система уравнений для оценки её параметров является линейной и имеет простое решение. Качество модели может быть проверено, а единственный настраиваемый параметр – порядок модели p – подлежит оптимизации для достижения наилучшей аппроксимации. Для выбора оптимального порядка были разработаны различные критерии, такие как

информационный критерий Акаике, метод Марпла, метод ковариации и его модификации. Отдельный подход, рассмотренный в [31], исходит из того, что ключевой задачей применения АР-модели для диагностирования подшипников качения является выделение импульсной составляющей из исходного сигнала. Соответственно, авторы предлагают выбирать порядок модели, максимизируя эксцесс остаточного сигнала, который содержит как импульсы, так и стационарный шум.

Методы анализа сигналов вибрации в частотной области применяются более широко, чем во временной. Полосовая фильтрация служит стандартным предварительным этапом обработки вибрационных сигналов, применяемым для выделения диагностически значимых частотных диапазонов. В дальнейшем отфильтрованный сигнал подвергается дополнительному анализу для получения требуемых характеристик, таких как форма временной реализации, спектр огибающей и другие.

Спектральный анализ наиболее часто применяется для исследования структуры вибрации, как наиболее точный способ обнаружения составляющих вибрации.

Широкое применение методов анализа вибрации в частотной области обусловлено в основном их возможностями в идентификации и выделении представляющих интерес отдельных частотных составляющих, чего не обеспечивает анализ во временной области. Следовательно, частотные методы являются чувствительными и надёжными в обнаружении и локализации дефектов. Тем не менее, их точность сильно зависит от, например, размера подшипника и скорости вращения. Кроме того, чтобы быть эффективными, эти методы требуют обоснования выбора полосы частот.

Анализ в частотной области позволяет идентифицировать характерные частоты, возникающие при наличии дефектов. Так, в подшипниках качения локальное повреждение генерирует периодические ударные импульсы в моменты контакта дефекта с другими поверхностями при вращении. Эти импульсы возбуждают резонансные частоты как элементов подшипника, так

и окружающей конструкции, что проявляется в росте вибрационной энергии в высокочастотной области. Расчётные значения характерных частот дефектов определяются геометрией подшипника и скоростью вращения в соответствии со следующими уравнениями [32, 33]:

$$\text{НК} = \frac{nf_r}{2} \left(1 - \frac{d}{D} \cos \theta \right), \quad (1.5)$$

$$\text{ВК} = \frac{nf_r}{2} \left(1 + \frac{d}{D} \cos \theta \right), \quad (1.6)$$

$$\text{СЕК} = \frac{f_r}{2} \left(1 - \frac{d}{D} \cos \theta \right), \quad (1.7)$$

$$\text{ТК} = \frac{D}{2d} \left[1 - \left(\frac{d}{D} \cos \theta \right)^2 \right], \quad (1.8)$$

где n – число элементов качения,

f_r – скорости вращения вала,

d – диаметр тел качения,

D – средний диаметр,

θ – угол контакта шарика (или ролика) с корпусом подшипника.

Уравнение (1.5) описывает частоту вибрации, возникающую при ударе тел качения по дефекту наружного кольца (характеристическая частота дефекта наружного кольца, НК). Уравнение (1.6) определяет аналогичную частоту для дефекта внутреннего кольца (ВК). Уравнение (1.7) соответствует частоте вращения сепаратора (СЭП), а уравнение (1.8) – частоте вращения тел качения (ТК). Теоретически данные частотные составляющие подлежат идентификации, при спектральном анализе огибающей вибрационного сигнала повреждённого подшипника. Помимо этих основных компонент, в спектре также могут присутствовать их гармоники и субгармоники, наличие которых служит индикатором нелинейного характера вибрации в целом.

Быстрое преобразование Фурье (БПФ) считается одним из распространенных методов извлечения компонентов частоты в сигнале. Полученный спектр, как правило, также содержит пик на частоте дефекта, если он не всегда чётко различим из-за скольжения и маскирования другими более сильными вибрациями. БПФ был впервые представлен в 1965 г. в [34] и главное новшество состоит в незначительном времени вычисления, необходимом для оценки преобразования Фурье размерности N , позволяющем сократить размер вычислений от N^2 до $N \log_2 N$ [35].

БПФ основано на эффективном методе оценки дискретного преобразования Фурье (ДПФ) от сигнала x , который представляет собой последовательность X вида:

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-\frac{j2\pi kn}{N}}. \quad (1.9)$$

Предыдущее уравнение описывает прямое преобразование, в то время как обратное преобразование представляет:

$$x(n) = \sum_{k=0}^{N-1} X(k) e^{\frac{j2\pi kn}{N}}. \quad (1.10)$$

Для оценки прямого преобразования ДПФ в уравнении (1.9) может быть введен элемент $W = e^{-j2\pi/N}$, так что оно будет выглядеть так:

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) W^{kn}. \quad (1.11)$$

Таким образом, этот алгоритм БПФ основан на свойствах элемента W и на бинарной декомпозиции индексов k и n .

Быстрое преобразование Фурье (БПФ) является базовым инструментом спектрального анализа, наиболее часто применяемым в комбинации с методами оценки спектральной плотности мощности. Спектр мощности представляет собой распределение энергии анализируемого сигнала по его частотным составляющим и определяется следующим образом:

$$E[X(f)X^*(f)], \quad (1.12)$$

где $X(f)$ – является преобразованием Фурье исходного сигнала $x(t)$,

$E[\]$ – ожидаемого значения,

"*" – комплексно-сопряжённое.

Поскольку алгоритм БПФ усредняет результаты по всей длительности сигнала, он не позволяет отследить временную динамику его спектрального состава. Это ограничение делает метод непригодным для анализа нестационарных процессов, типичных для вращающегося оборудования, где возникает необходимость установления взаимосвязи между временной и частотной составляющими сигнала. Кроме того, спектр мощности часто не позволяет чётко идентифицировать пик на характерной частоте дефекта из-за явлений скольжения и маскирующего влияния более интенсивных вибрационных составляющих. Решением данной проблемы является применение метода спектра огибающей.

Огибающая сигнала $x(t)$ формируется путём вычисления комплексной аналитической функции, вещественная часть которой совпадает с исходным сигналом, а мнимая представляет собой его преобразование Гильберта. Это преобразование во временной области может быть получено через фазовый сдвиг спектра исходного сигнала с последующим обратным преобразованием Фурье либо сформировано из его одностороннего спектра, что исключает необходимость манипуляций с фазой отдельных частотных компонент. Математическое выражение для преобразования Гильберта сигнала во временной области имеет следующий вид:

$$H[x(t)] = \tilde{x}(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau, \quad (1.13)$$

и огибающая рассматриваемого сигнала

$$E[x(t)] = \sqrt{x^2(t) + \tilde{x}^2(t)}. \quad (1.14)$$

Методы анализа сигналов вибрации в частотно-временной области. Спектральный анализ не применим для обработки нестационарных сигналов, которые часто наблюдаются при возникновении неисправностей в оборудовании. Данную проблему решает частотно-временной анализ, позволяющий одновременно исследовать сигнал как во временной, так и в частотной области. Однако ключевым ограничением этого подхода выступает «принцип неопределённости», согласно которому произведение временного разрешения Δt и частотного разрешения Δf является величиной постоянной. Таким образом, повышение точности по одной из координат неизбежно приводит к снижению точности по другой.

К наиболее распространённым методам в диагностировании неисправностей можно отнести следующие методы анализа сигналов вибрации в частотно-временной области.

Преобразование Фурье (ПФ) считается одним из методов и широко применяется в области обнаружения и диагностирования неисправности (ОДН). Преобразование Фурье определяет, какие частоты присутствуют в данных сигнала. Определение ПФ в качестве интегрируемой функции представляет:

$$Y(f) = \int_{-\infty}^{+\infty} x(t)e^{-2j\pi ft} dt . \quad (1.15)$$

где $Y(f)$ - является амплитудой ПФ при заданной частоте f . Значение $x(t)$ соответствует амплитуде сигнала в данный момент времени. Результат преобразования Фурье может быть построен в двумерном графике с частотой и амплитудой, как размерностями.

Основной недостаток ПФ заключается в том, что информация, полученная с помощью преобразования Фурье, не имеет временной размерности. Поэтому оно не несёт в себе информацию о том, “когда” определённая частота появилась в сигнале. Это делает метод ПФ недоступным для нестационарных сигналов, если требуется определить время, когда происходят определённые спектральные компоненты. Для обнаружения и

диагностирования неисправностей это считается распространённой ситуацией. Действительно, отсутствие временной размерности значительно уменьшает количество информации, извлекаемой из сигнала.

Оконное преобразование Фурье (ОПФ) можно рассматривать как промежуточный этап между Фурье и вейвлет-преобразованиями. ОПФ работает таким же образом, как и стандартное преобразование Фурье, но вместо того, чтобы оценить частоту по всем данным сигнала, оно ограничено конкретным временным окном. Окно математически реализуется функцией окна ω , что переводит по всем данным в качестве значения изменения τ . Функция окна умножается на функцию амплитуды x . Эффект в том, что значения сигнала, удалённого во времени с точки трансляции τ , будет умножен на величину, близкую к 0, и, следовательно, не будет в значительной мере влиять на значение ОПФ. Для каждой частоты и передающей точки значение оконного преобразования Фурье может быть определено с помощью следующей функции:

$$Y^w(\tau, f) = \int_{-\infty}^{+\infty} x(t) \omega(t - \tau)^{-2j\pi ft} dt. \quad (1.16)$$

Его результат может быть построен в трёх измерениях: частота, амплитуда и время. ОПФ может быть использовано для анализа нестационарных сигналов, но оно имеет существенный недостаток, который может препятствовать его осуществлению в реальном приложении: оконная функция и, следовательно, её ширина, фиксируется. Она не изменяется динамически в процессе оценки функции. Чем уже окно, тем хуже разрешающая способность по частоте она получает (идентифицируемые частоты заключены в определённые пределы в ограниченной полосе). В случае широкого окна, напротив, получим плохое разрешение по времени. Поэтому с помощью этого метода не представляется возможным одновременно получить хорошее разрешение по времени и по частоте.

Особенности содержания и применения отдельных методов из аналитического инструментария будут исследованы в формате конкретных

этапов обнаружения и диагностирования неисправностей в последующих разделах диссертации.

Таким образом, проведенные исследования аналитического инструментария обработки данных технического состояния машин и оборудования, позволили сделать следующие выводы:

1. Структурированы и идентифицированы особенности применения в обработке исходных сигналов методов аналитического инструментария;

2. Исходные характеристики неисправности, полученные при современных методах обработки сигналов, содержат определённую избыточность. При использовании таких сигналов для выявления состояния технических систем скорость обнаружения неисправностей может быть низкой. Следовательно, уже на этапе первичной обработки данных необходимо использовать методы интеллектуального анализа данных, чтобы устранить ненужные функции до постановки диагноза;

3. Классические методы, в том числе спектральный анализ, средние значения временной области, детектирование огибающей и т.д., являются неэффективными для выделения признаков нестационарных сигналов;

4. Методы интеллектуального анализа данных нашли широкое применение в мониторинге состояния технических систем, как на этапах первичной обработки сигнала, так и на этапах диагностирования неисправностей.

1.2 Анализ методов отбора диагностических признаков для обнаружения неисправностей технических систем

В технических системах можно измерять большое количество различных признаков неисправностей от различных датчиков. Это приводит к проблеме чрезмерно высокой размерности данных. Высокая размерность не только уменьшает скорость вычислений алгоритмов обнаружения и диагностирования неисправности, но может также снижать их точность [36].

В этой связи, в моделях управления данными ОДН, снижение количества признаков является важным этапом предварительной обработки данных.

При этом, несмотря на большое количество исходных признаков, только относительно малое подмножество данных имеет ценность для целей ОДН. Выбор наиболее информативных признаков считается лишь частичным решением. Отбракованные признаки могут содержать небольшой, но релевантный объём знаний. Улучшенные характеристики могут быть получены проецированием подмножества исходных в новые векторы признаков. Эти новые векторы выбираются в соответствии с некоторым критерием, максимизирующим количество релевантных знаний, которые они содержат. Таким образом, все исходные признаки могут принести свой вклад в конечное, меньшее множество новых признаков.

Эффективность методики диагностирования в значительной степени зависит от качества используемых признаков. При этом важно выбирать их, насколько это возможно, в надлежащем сочетании, которое может содержать релевантную информацию о неисправности. В частности, в случае переменных условий работы, признаки, в явной или неявной формах, должны содержать всю информацию об этих вариациях. Пример процедуры извлечения признаков, можно рассмотреть на блок-схеме на рисунке 1.7.

Первым этапом формирования признакового пространства является извлечение характеристик с применением одного из методов обработки сигналов: временного, частотного или частотно-временного анализа. Выбор конкретного метода определяется его чувствительностью к различным типам дефектов и условиям эксплуатации, а также спецификой диагностируемой технической системы. Для достоверного обнаружения неисправности, как правило, недостаточно ограничиться одним признаком; эффективная классификация требует использования их совокупности, при этом существенное значение имеет взаимосвязь и информативность каждого из них. Критическим аспектом является и количество признаков, поскольку их

избыточность может снизить эффективность модели. Таким образом, ключевой задачей становится формирование такого набора признаков, который обладает максимальной представительностью и обеспечивает высокую точность классификации.

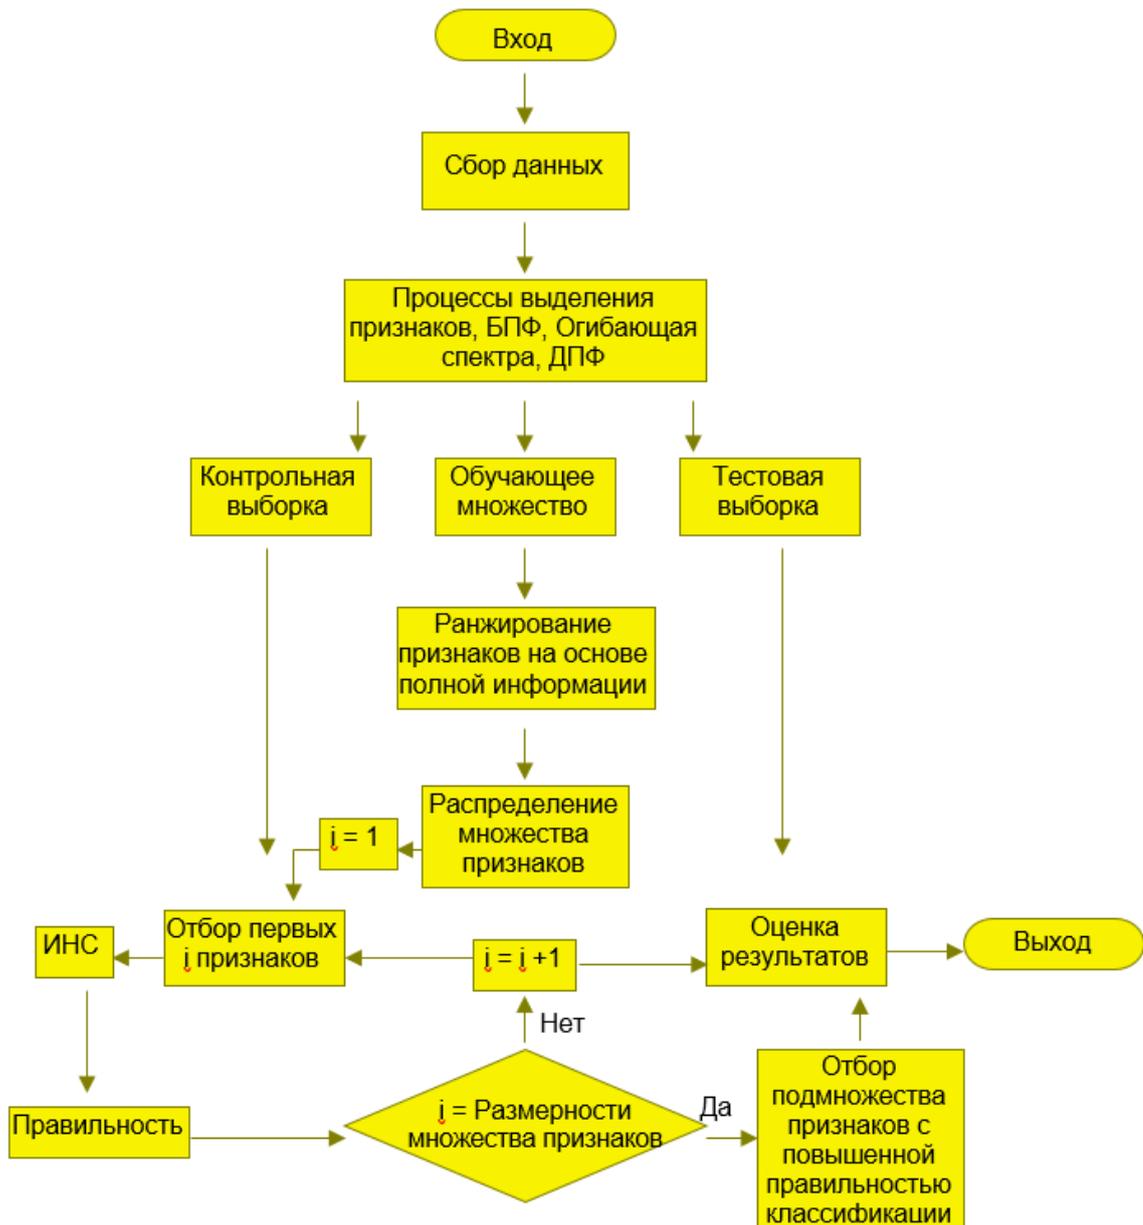


Рисунок 1.7 – Алгоритм отбора признаков, выделенных из сигнальной информации при вибродиагностировании технических систем

Для выбора наиболее информативных диагностических признаков применяются различные методы, среди которых можно выделить модифицированную методику отдалённости отличительных признаков,

методику оценки отдалённости, алгоритмы на основе искусственных нейронных сетей, дерево решений J48 [37]. Корректный выбор метода фильтрации и ранжирования признаков является принципиально важным для повышения эффективности диагностирования.

Процесс определения неисправностей заключается в классификации сформированного набора признаков по соответствующим категориям состояний. Для этого используется интеллектуальный инструментарий, осуществляющий отображение пространства признаков на решения в системе диагностирования. Традиционные подходы включают методы классификации образов, экспертные системы, основанные на знаниях, и численное моделирование. В рамках этих методов специалисты ориентируются на характерные особенности в вибрационных сигнатурах, указывающие на наличие дефекта. В качестве альтернативы могут применяться методы статистического анализа и искусственные нейронные сети (ИНС), используемые в автоматизированных системах обнаружения неисправностей. ИНС приспособлены к изучению поведения нелинейных систем. В системах нечёткой логики из экспертной базы знаний извлекается набор логических правил, не зависящих от конфигурации системы. Liu и соавт. [38] разработали нечёткую экспертную систему для диагностики подшипников. Окончательное диагностирование выполняется с использованием алгоритмов классификации. Sugumaran и Ramachandran [39] применили правила автоматического обучения с использованием дерева решений для нечёткого классификатора в диагностике неисправностей роликовых подшипников. Набор правил формируется из выделенных признаков и входов в нечёткий классификатор.

Дерево решений используется для автоматической генерации правила из множества признаков. Nguyen и соавт. [40] использовали генетический алгоритм для оптимального отбора признаков механического обнаружения неисправностей индукционного двигателя. На основе конкретных критериев отдалённости, вводится генетический алгоритм для снижения числа признаков. Дерево решений и мульти-классовый метод опорных векторов

(МОВ) используются для иллюстрации потенциала и эффективности этого метода отбора (классификации).

Рассмотрим особенности наиболее широко используемых в обнаружении и диагностировании неисправностей методов отбора их признаков.

Анализ главных компонент. Большинство методов выделения диагностических признаков базируется на линейных методах обработки данных, таких как анализ главных компонент (АГК) и анализ независимых компонент. АГК, являясь фундаментальным статистическим инструментом в задачах управления данными, находит применение практически на всех этапах обнаружения и диагностирования неисправностей. Его ключевые преимущества связаны с высокой вычислительной эффективностью и способностью работать с массивами данных большой размерности.

Концепция АГК ориентирована на создание набора базисных признаков, которые могут оптимально моделировать данные в смысле минимальной погрешности. Метод анализа главных компонент обеспечивает линейное преобразование некоторого числа n m -мерных входных векторов x_i , где $i = 1, \dots, n$ и $m < n$, в новых векторах s_i через преобразование:

$$S_i = V^T x_i, \quad (1.17)$$

где V – является $m \times m$ ортогональной матрицей, в которой в каждой колонке v_j присутствует собственный вектор образца ковариационной матрицы

$$C = \frac{1}{n} \sum_{i=1}^n x_i x_i^T. \quad (1.18)$$

Это означает, что АГК решает задачу о собственных значениях

$$A_j v_j = C v_j, \quad j = 1, \dots, m \quad (1.19)$$

в точках λ_j являющихся собственными значениями C и v_j , соответствующими собственному вектору.

Когда вычисляется ортогональное преобразование входного вектора x_i , получают различные компоненты s_i , которые называются главными компонентами:

$$S_i(j) = v_j^T x_i, \quad j = 1, \dots, m \quad (1.20)$$

Если собственные значения сортируются в порядке убывания, то можно выбрать только первый из них, чтобы уменьшить число главных компонент в s_i . При этом возможно снижение размерности АГК. Более того, главные компоненты представляют некоторые характеристики по $s_i(j)$, являющиеся некоррелированными и они последовательно показывают максимальные отклонения. Кроме того, средний квадрат погрешности аппроксимации в представительстве исходных входов через первые несколько главных компонент является минимальным [41].

Если исходить из n -мерных данных, можно обобщить несколько важных понятий АГК:

- Ковариационная матрица представляет собой $n \times n$ матрицу, рассчитанную таким образом, что, учитывая два индекса i и j , значение $x_{i,j}$ (или $x_{j,i}$), формируется ковариацией между i -й размерностью и j -й размерностью для приведенных данных.

- Собственные векторы вычисляются с использованием матрицы n ковариации. Эти векторы являются n -мерными и ортогональны друг другу.

- Собственные значения. Для каждого собственного вектора может быть вычислено собственное значение. Если точки измерений представлены с размерностью, соответствующей собственному вектору, то его собственное значение указывает величину дисперсии, которую имеют точки измерений. На интуитивном уровне, собственное значение указывает на то, каким будет “хороший” вектор, если он должен быть использован в качестве размерности.

Собственные векторы ранжированы от самого высокого собственного значения основного компонента до самого низкого уровня. По такому же принципу могут быть отброшены собственные векторы с самыми низкими собственными значениями. Размерность данных снижается при их распределении только в оставшихся p собственных векторов. Если собственные значения отброшенных собственных векторов будут низкими, потери информации будут также незначительными.

- Вектор признака представляет $n \times p$ матрица с одним из оставшихся собственных векторов для каждого столбца. Этап восстановления размерности производится перемножением двух матриц. Первая матрица представляет собой транспонированный вектор признака, имеющий собственные векторы в строках, а не в столбцах (матрица становится $p \times n$). Вторая матрица сформирована как столбец точек измерений. Если точки измерений представляют l , то матрица будет $n \times l$. Результатом этого матричного перемножения является n -мерный массив данных, сниженный до l -размерности.

Применение АГК для решения задач обнаружения и диагностирования неисправностей подробно рассмотрена в работах [42-45]. Данный процесс реализуется в три последовательные стадии. Исходные данные представляются в виде n выборок, каждая из которых имеет размерность m , соответствующую, при отсутствии предварительной обработки, количеству датчиков в системе мониторинга.

- Первая стадия включает сбор данных и их нормализацию. Исходные выборки формируются в выборочную матрицу размерностью $n \times m$. Затем выполняется центрирование данных, в результате которого каждая размерность (столбец матрицы) приводится к нулевому математическому ожиданию, что генерирует новую матрицу X .

- На второй стадии производится определение контрольных порогов. На основе матрицы X вычисляется ковариационная матрица, после чего идентифицируются главные компоненты, для чего типичным способом является метод сингулярного разложения (МСР). Используя полученные главные компоненты, рассчитываются пороговые значения для двух статистик: квадрата ошибки прогнозирования и статистики Хотеллинга (Hotelling T^2 distribution).

- Заключительная стадия – непосредственное обнаружение неисправностей. Новые поступающие измерения масштабируются (центрируются), и для них вычисляются текущие значения статистик и

значения T^2 распределения Хотеллинга. Если хотя бы одна из этих величин превышает соответствующий рассчитанный порог, фиксируется факт наличия неисправности.

С другой стороны, анализ независимых компонент (АНК), является сравнительно новым методом, который можно рассматривать как обобщение АГК. Данный подход позволяет найти линейное преобразование для наблюдаемых данных, представляя их в виде набора базисных компонент, которые не только декоррелированы, но и статистически независимы в строгом смысле. АНК может применяться для выделения независимых компонент из смешанных сигналов. Критерий независимости подразумевает, что информация, переносимая одной компонентой, не может быть выведена из других. Статистически это выражается в том, что совместная плотность вероятности независимых величин равна произведению их распределений. Модель АНК для матрицы измеренных данных X описывается следующим образом:

$$X = As, \quad (1.21)$$

где A – неизвестная матрица смешивания;

s – независимая матрица данных компонент.

Целью данной методики является оценка независимой матрицы компонент или матрицы смешивания, зная только измеренные данные матрицы x . Практически, необходимо обратиться к этой бывшей матрице, так называемой разделяющей матрице W :

$$\hat{S} = Wx, \quad (1.22)$$

которая гарантирует компонентам реконструированной матрицы данных \hat{s} быть максимально независимыми, насколько это возможно.

Это последнее требование эквивалентно принятию того, что они не принадлежат к распределению Гаусса. Способ достичь это состоит в оптимизации некоторой меры негауссовости вектора Wx .

Дискриминантный анализ Фишера (ДАФ) представляет собой метод снижения размерности и особенно подходит для задач классификации

признаков. Этот метод управления данными и его эффективность строго зависят от качества и количества обучающих данных. ДАФ ориентирован на формирование, насколько это возможно, классов, как разложимых. Это отличается от АГК. АГК, стремится к способности представлять данные с меньшей размерностью. Однако анализ главных компонент не предусматривает разделения классов.

Дискриминантный анализ Фишера возможно применять в обнаружении и диагностировании неисправностей. Во-первых, генетические алгоритмы используются для определения оптимальных переменных, применяемых в вычислении ДАФ. После фазы выбора признаков для классификации используются дискриминанты Фишера и МОВ. Показатель ошибки классификации оказывается около 6%. В то же время ДАФ достиг только 18% показателя ошибочной классификации. Дискриминантный анализ Фишера не в состоянии достаточно хорошо адаптироваться к нелинейным задачам.

Деревья решений являются распространённым типом классификаторов и этот метод особенно ценится в области обнаружения и диагностирования неисправностей для интерпретации получаемых решений. Фактически, задача классификации с использованием дерева решений выполняется с помощью набора правила “если-то”. Это позволяет дереву решений объяснять свой результат. Закономерность не присутствует во всех методах классификации. Искусственные нейронные сети являются стандартным примером не интерпретируемого процесса рассуждения.

Алгоритм С4.5 представляет собой статистический классификатор. Он использует множество уже классифицированных обучающих выборок и его результатом является дерево решений. Основная идея применения этого алгоритма заключается в увеличении энтропии. Учитывая атрибут x , его коэффициент увеличения энтропии интуитивно может быть описан как разница между количеством информации, необходимой для классификации элемента обучающего множества, и количеством информации, необходимой для выполнения той же самой задачи классификации, но в случае, когда

атрибут x известен. В каждом узле дерева решений, атрибут с наибольшим коэффициентом увеличения энтропии является атрибутом, выбранным для формирования правила решений.

В работе [46] представлен пример дерева решений, как метода классификации признаков неисправности. Это исследование используется алгоритм J48 для классификации в обнаружении и диагностике неисправностей дефектов подшипников. Алгоритм J48 реализован на Java с открытым исходным кодом алгоритма C4.5. Алгоритм J48 достиг удовлетворительной точности классификации (больше 93%).

Основываясь на принципе увеличения энтропии, алгоритм C4.5 был предложен для выбора отбора признаков в нескольких работах. В каждом узле дерева решений, генерируемых алгоритмом C4.5, признак используется для оценки правила принятия решения. Если узел находится близко к корню в дереве решений, признак обладает высокой способностью распознавания для данной задачи классификации. С другой стороны, если признак используется в узле, далёком от корня, то, вероятно, признак уже плохой классификатор. Кроме того, признаки, которые вообще не используются в дереве решений, должны быть отброшены, поскольку они не являются необходимыми для решения задачи классификации.

Такое использование алгоритма C4.5 описано в [46]. Сначала обучающее множество составляло 11 признаков. Тогда точность классификации байесовской сети оценивали с учётом только верхних- x признаков, в соответствии с C4.5 сгенерированного дерева решений. Используя только первый признак (тот, что используется в корне) была достигнута точность классификации 73,33%. Существенное различие было отмечено при добавлении второго признака – уровень точности достиг 87,22%. Увеличение количества признаков, с двух до шести признаков в целом привело к повышению точности, но незначительно. При этом, начиная от шестого признака, точность незначительно снижалась. После этого эксперимента, 6 самых верхних признаков в дереве решений были определены как

оптимальная группа признаков для использования в задаче классификации. В работе [46] показана возможность выбора признаков с помощью алгоритма C4.5.

Тем не менее, побочный эффект принципа увеличения энтропии и этот алгоритм не предназначены для использования в качестве селектора признаков. В [46] обсуждается эффективность этой стратегии, и выявлен ряд её недостатков. В частности оказалось, что лучший признак выбирается только в корневом узле. В любом другом узле, выбор лучшего признака зависит от подмножества атрибутов, которые узел может использовать. Кроме того, было отмечено, что выбор параметров сильно зависит от размера выборки данных. Следовательно, в общем случае, алгоритм C4.5 не приведёт к оптимальному отбору признаков неисправности, и специальные методы считаются гораздо более эффективными для решения этой задачи.

Вопрос оптимального формирования набора диагностических признаков для подшипников качения рассматривается в работе Sugumaran и соавт. [47]. где для их отбора использовались деревья решений, показавшие высокую эффективность в сочетании с методом опорных векторов (МОВ). Mahli и Gao разработали комплексный набор признаков во временной, частотной и вейвлет-областях, который в дальнейшем обрабатывался методом главных компонент для снижения размерности [48]. В качестве альтернативного инструмента, способного генерировать новые признаки без априорных знаний о распределении данных, может применяться генетическое программирование.

Другой подход, основанный на критерии взаимной информации для выбора признаков, представлен в исследовании [49]. Этот метод позволяет интегрировать модели и данные, выполняя их ранжирование по информативности. Данный статистический метод обеспечивает оценку и сравнение признаков независимо от выбранного классификатора, формируя упорядоченный оптимальный набор, который часто включает признаки из разных областей анализа, что в целом повышает точность классификации.

Процедура ранжирования предоставляет важную информацию для понимания поведения системы и условий её эксплуатации, создавая основу для обоснованного выбора признаков, наиболее подходящих для диагностирования и прогнозной аналитики. Как отмечается, анализ взаимной информации также помогает выявить наиболее значимые признаки для решения задач диагностики.

Таким образом, проведенные исследования методов отбора признаков при обнаружении неисправностей, позволяют сделать следующие выводы.

1. Проведена структуризация и раскрыты особенности различных методов отбора признаков при обнаружении неисправностей.

2. При проведении диагностирования в сложных технических системах можно измерять большое количество различных признаков неисправностей от различных датчиков. Это приводит к проблеме чрезмерно высокой размерности данных. Высокая размерность, не только уменьшают скорость вычислений алгоритмов автоматического обнаружения и диагностирования неисправности, но может также снизить их точность.

3. Определение неисправности влечёт за собой классификацию признаков по различным категориям. Для этой цели, используется инструментарий интеллектуальной обработки данных для отображения признаков.

1.3 Анализ методов обнаружения неисправностей технических систем

Появление и выражение неисправности проявляется в виде различных аномалий, возникающих в работе технических систем и их элементов. Понятие «обнаружение аномалий» в диагностировании оборудования относится к идентификации закономерностей (patterns – образцы, шаблоны, паттерны) в заданном множестве данных, которые не соответствуют установленному нормальному функционированию. Эти несоответствующие паттерны (сигнатуры, в случае вибрационного анализа) часто называют аномалиями, выбросами, несогласованными наблюдениями или

отклонениями. В частности, как показал литературный анализ, «аномалии» и «выбросы» являются двумя наиболее используемыми терминами в контексте обнаружения аномалий и, иногда, они также являются взаимозаменяемыми. Обнаружение выбросов или аномалий в данных является объектом множества исследований и разработок в области методов статистики, машинного обучения и интеллектуального анализа данных [50].

Обнаружение аномалий относится к обнаружению закономерностей в данных, которые не соответствуют принятым определённым понятиям нормального функционирования. Пример аномалии показан на рисунке 1.8, где представлены 2-мерные множества данных [51]. Эти два множества данных, обозначенные как N_1 и N_2 , рассматриваются как области нормального поведения, поскольку большинство наблюдений лежат в этих двух областях. Точки o_1 , o_2 , и область O_3 рассматриваются как аномалии, потому что они находятся достаточно далеко от областей N_1 и N_2 .

Аномалии в данных могли быть вызваны разными причинами. Основные причины часто неизвестны, поскольку несколько источников также могут привести к появлению аномалии. Например, если объект принадлежит к другому типу или классу совокупности данных, то его можно рассматривать как аномалию. Этот факт отмечается в часто цитируемом определении выбросов статистика D. Hawkins [52]: выбросом является наблюдение, которое настолько сильно отличается от других наблюдений, чтобы вызвать подозрение, что оно было порождено другим механизмом. Примерами могут служить вторжения в информационные системы и аномальные результаты испытаний. Эти аномалии, как правило, в центре внимания обнаружения аномалий методами интеллектуального анализа данных.

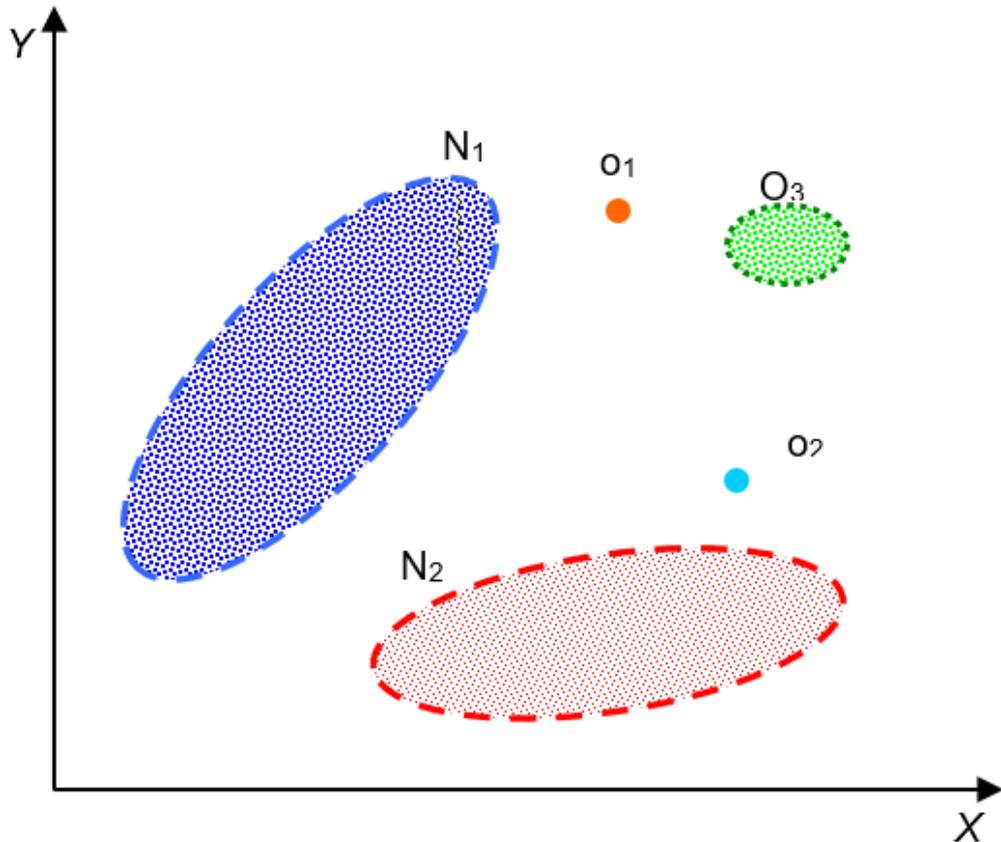


Рисунок 1.8 – Пример аномалий в 2D множестве данных

Иногда ошибки могут возникать в процессе сбора данных и измерений. Ещё один источник аномалии возникает из-за ошибки оператора при наличии шума или проблемы с измерительным прибором. В этом случае качество данных снижается, также как последующий анализ данных. Тип обработки данных, названный очисткой данных, связан с удалением этих аномалий. Интересный тип аномалии представлен крайностями или маловероятными вариантами. Формально, можно говорить о естественной изменчивости, поскольку большинство объектов расположено вблизи центра и вероятность того, что элемент отличается от этого среднего объекта, мала.

Важным аспектом для любого метода обнаружения аномалий является способ, в котором аномалии представляются как выдаваемые данные. Это может быть выполнено обычной оценкой или маркировкой. Методы оценки присваивают аномальную оценку каждому экземпляру в тестовых данных в зависимости от того, в какой степени этот экземпляр считается аномалией.

Следовательно, составляется ранжированный список аномалий, как выдаваемые данные. В другом случае метка (нормальный или аномальный) назначается каждому образцу теста. Концепция маркировки также связана с различными подходами, которые могут ориентироваться на обнаружение аномалий. Рассмотрим содержание методов, основанных на классификации, достаточно полно отражающее, природу обнаружения аномалий в контексте данной работы.

Методы обнаружения неисправностей на основе классификации действуют в качестве более общей классификации: после того, как на первой стадии, когда модель была сформирована из множества отмеченных объектов данных, новый образец заносится (классифицируется) в один из классов, определённых в модели. Эти два этапа названы обучение и тестирование, соответственно. Если говорить о методах обнаружения аномалий, то используются имеющиеся маркированные обучающие данные для построения классификатора, который позволил бы утверждать, является ли новый образец теста нормальным или аномальным [53].

Классификация основана на маркировке данных, являющейся одновременно и обучением и тестированием. Учитывая метки, доступные для образцов данных обучения, методики обнаружения аномалий на основе классификации могут быть сгруппированы в две широкие категории: многоклассовая классификация и методы обнаружения аномалий одного класса. Основное различие между этими двумя подходами определяется числом классов, которые могут быть помечены в процессе обучения. Фактически, классификации методов обнаружения аномалий на основе нескольких классов предполагают, что данные обучения содержат маркированные образцы, принадлежащие множеству нормальных классов. Таким образом, классификатор обучает различать между каждым нормальным классом по отношению к остальным классам. Это означает, что новый тестируемый образец считается аномальным, если он не классифицируется как нормальный любым из классификаторов (рисунок 1.9).

В некоторых случаях степень уверенности связана вместе с предварительной оценкой, сделанной классификаторами, и если ни один из них не уверен в классификации тестового образца как нормального, это образец аномального маркирования. Если, вместо этого, все обучаемые образцы принадлежат к единственному классу, то здесь случай методики обнаружения аномалий одного класса на основе классификации. Центральным моментом большинства такого рода методов является определение границы обучающих нормальных случаев с использованием алгоритма классификации в одном классе. В случае любого нового тестового образца, если он не попадает под границы обучающих, то он помечается как аномальный. Пример такой процедуры представлен на рисунке 1.10.

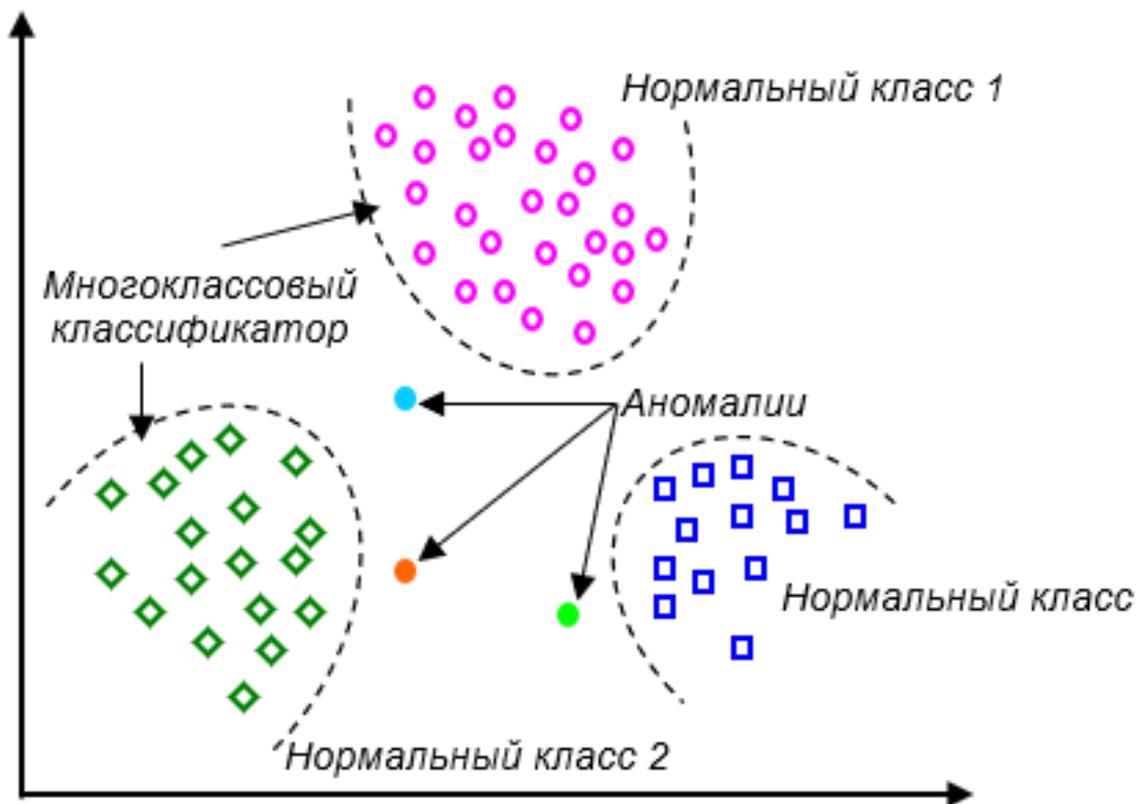


Рисунок 1.9 – Пример многоклассовой классификации

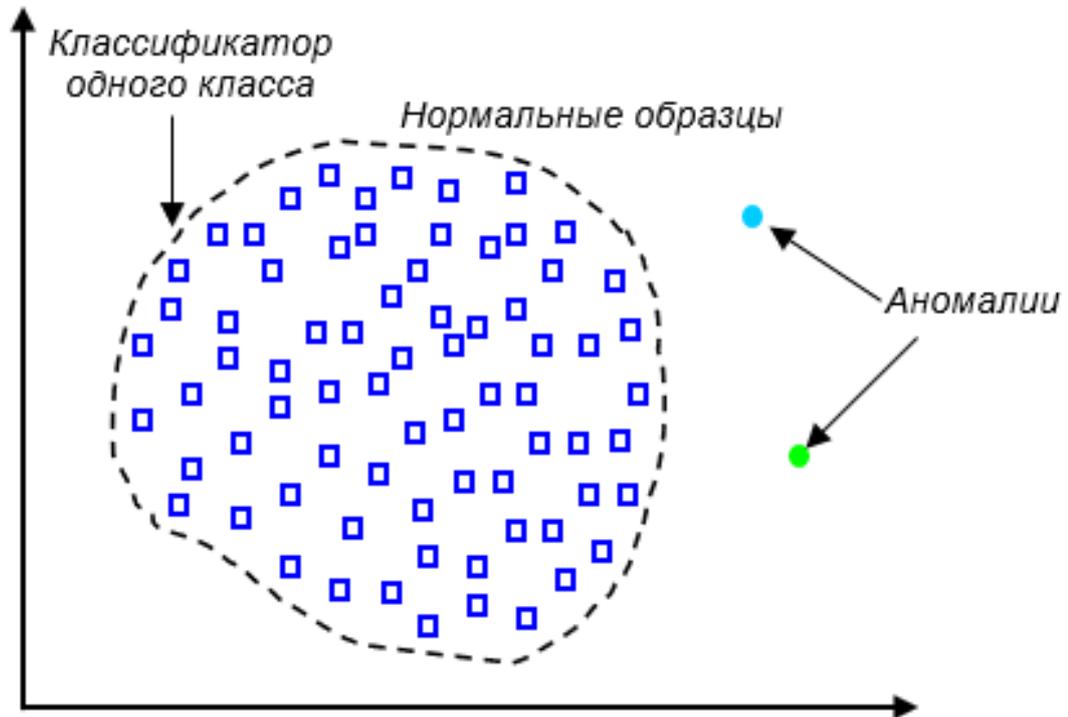


Рисунок 1.10 – Пример классификации одного класса

Методики, основанные на классификации, и особенно многоклассовые методы, имеют большие преимущества, позволяющие использовать алгоритмы, способные различать образцы, принадлежащие к различным классам. Кроме того, этап тестирования является быстрой процедурой, потому что каждый объект испытаний должен сравниваться с предварительно вычисленной моделью. Однако при этом необходимо учитывать некоторые недостатки при использовании некоторых методов на основе классификации. В случае многоклассовых методов, необходимо учитывать, что они полагаются на наличие точных меток для различных нормальных классов, что часто не представляется возможным.

В общем случае, существует несколько перекрывающихся друг друга таксономий методов обнаружения неисправностей. В частности, ГОСТ Р ИСО 13379-1-2015 Контроль состояния и диагностика машин выделяет два подхода и, соответственно, две группы методов диагностирования неисправностей технических систем.

- Подход на основе данных включает в себя методы построения и анализа трендов, нейронных сетей, распознавания образов, статистического анализа, диаграмм Парето и прочие численные методы. В частности: статистический анализ данных и анализ случаев из практики; нейронные сети; деревья классификации; случайный лес; логистическая регрессия; метод опорных векторов.

- Подход на основе знаний включает в себя модели развития неисправности, модели нормального функционирования системы или описания типичных ситуаций в поведении системы.

Для цели работы наиболее представительным будет краткое изложение содержания методов обнаружения неисправностей оборудования, при следующей структуризации этих методов:

1) Методы данных и модели сигналов:

- проверка границ и проверка тенденций;
- анализ данных (АГК);
- спектральный анализ и параметрические модели;
- распознавание образов (нейронные сети).

2) Методы, основанные на модели процесса:

- проверочные уравнения на чётность;
- наблюдение состояния;
- оценка параметров;
- нелинейные модели (нейронные сети).

3) Методы, основанные на знаниях:

- экспертные системы;
- нечёткая логика.

Методы, основанные на обработке данных сигналов, используют только имеющиеся экспериментальные (исторические) данные:

- Проверка границ и проверка тенденций

Принимаются два предельных значения порога – максимальное значение Y_{max} и минимальное значение Y_{min} . Нормальное состояние считается, когда

$$Y_{min} \leq Y(t) \leq Y_{max}. \quad (1.23)$$

Этот метод может быть также применён к первой производной (проверка называется тенденцией)

$$\dot{Y}_{min} \leq \dot{Y}(t) \leq \dot{Y}_{max}. \quad (1.24)$$

Основным достоинством метода контроля границ считается его простота и надёжность, однако он способен реагировать лишь на значительные изменения в значениях диагностических признаков, что приводит к запаздыванию в обнаружении дефектов [54, 55]. Кроме того, поскольку распределение данных в нормальном режиме работы часто отличается от гауссового, для его аппроксимации могут применяться модели смеси гауссовых распределений [56].

- Обнаружение неисправностей с помощью анализа главных компонент. Анализ главных компонент использует ортогональное преобразование для перевода множества наблюдений, возможно, коррелированных переменных, в множество значений некоррелированных переменных, называемых главными компонентами. Он определяется линейным преобразованием матрицы $P_{[m \times r]}$, $r < m$ (его определение требует нескольких шагов расчёта матрицы), которая преобразует матрицу $X_{[N \times m]}$ входных данных в $T_{[N \times r]}$ группы ортогональных данных (оценка главных компонент).

$$T_{[N \times r]} = X_{[N \times m]} P_{[m \times r]}. \quad (1.25)$$

Анализ главных компонент снижает размерность множества данных с учётом большого числа взаимосвязанных переменных, сохраняя при этом как можно больше вариаций, присутствующих в множестве данных. Это обеспечивает возможность обработки и мониторинга больших пространственных данных [54, 55]. Обнаружение неисправностей осуществляется путём применения обнаружения изменений на преобразованных данных T с учётом допустимых средних значений μ_j и

дисперсий σ_j^2 (рисунок 1.11). Расширение метода главных компонент для решения динамических систем предлагается в работе [57].

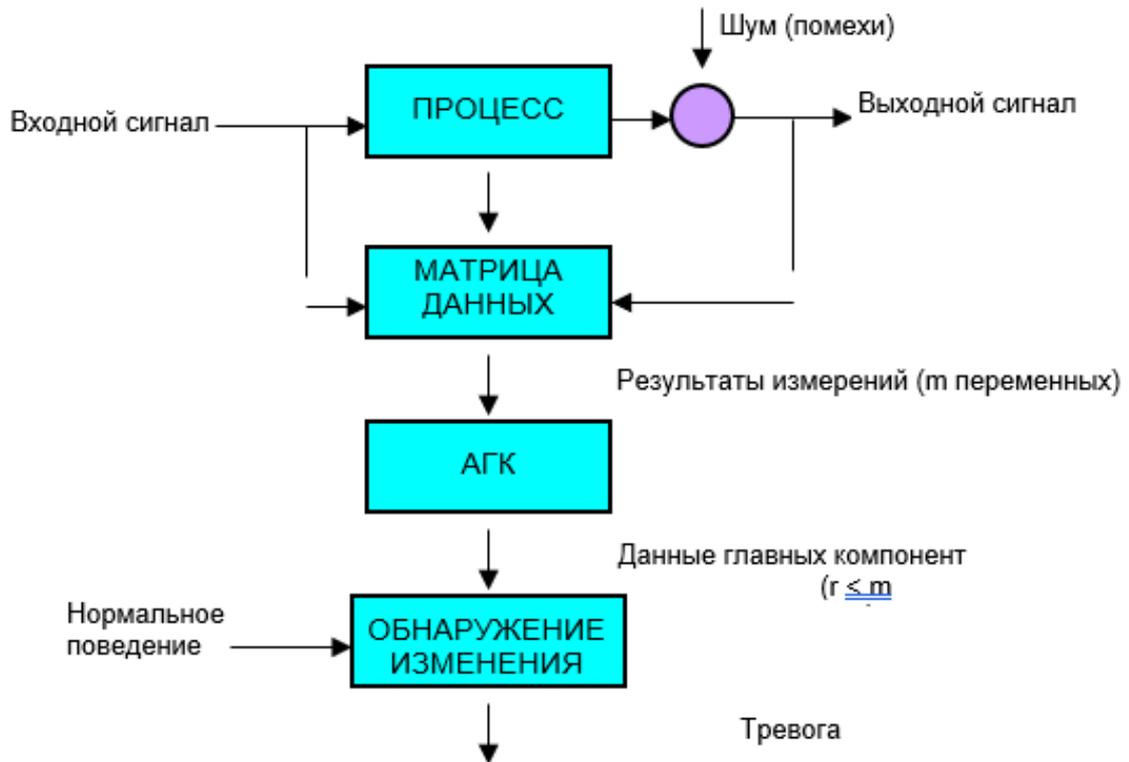


Рисунок 1.11 – Обнаружение неисправностей с помощью анализа главных компонент (АГК)

- Обнаружение неисправностей с помощью моделей сигналов

Для выявления изменений в сигнале, обусловленных возникновением неисправностей в технологическом процессе, может быть использован анализ сигнала на основе математических моделей [54, 55]. В рамках данного подхода для измеряемого сигнала формируется математическая модель, на основе которой вычисляются соответствующие характеристики, такие как амплитуды, фазы и спектральные составляющие. Последующее сравнение полученных характеристик с эталонными значениями, соответствующими нормальному режиму работы, позволяет выявить отклонения, которые интерпретируются как диагностические признаки. Общая схема данного процесса представлена на рисунке 1.12 [54].

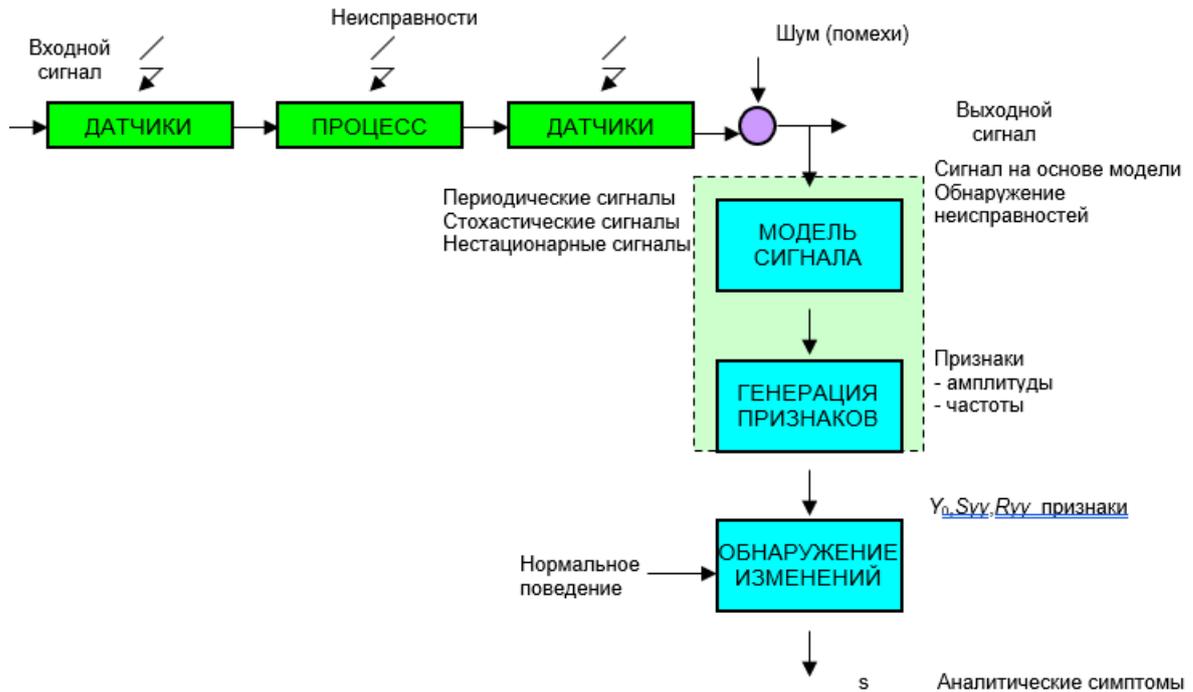


Рисунок 1.12 – Обнаружение неисправностей с моделями сигналов

- Спектральный анализ

Выделение характеристик сигнала, соответствующих неисправности может быть ограничено амплитудой или амплитудной плотностью в пределах определённой ширины полосы сигнала. Эффективный алгоритм быстрого преобразования Фурье (БПФ) может быть использован для расчёта частотного содержания сигнала $x(t)$. Во время нормальной работы компоненты A_i находятся в пределах определённого диапазона:

$$x(t) = A_0 + \sum_{i=1}^N A_i \sin(\omega_i t + \theta_i) \quad (1.26)$$

$$A_{i, \min} \leq |A_i| \leq A_{i, \max}. \quad (1.27)$$

- Модели параметрического сигнала

Также могут быть использованы модели параметрического сигнала, такие как авторегрессионное скользящее среднее (АРСС) [62, 63]. АРСС (p,q) относится к модели с p авторегрессией условия φ_i и q скользящей средней условия θ_i , константы c и ошибок условия $\varepsilon_t, \varepsilon_{t-i}$:

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i}. \quad (1.28)$$

Параметрические модели очень чувствительны к малым изменениям частоты.

- Распознавание образов, нейронные сети

Нейронные сети находят успешное применение в задачах распознавания образов, что делает их подходящим инструментом для обнаружения неисправностей [58]. При использовании контролируемого обучения сети предъявляются пары «вход-выход», соответствующие как нормальным условиям, так и различным режимам неисправностей. В случае недостатка реальных данных о дефектах в обучающей выборке, её объем может быть расширен за счёт модельных данных, полученных путём имитации повреждений. В исследовании, проведенном сотрудниками ФГБНУ ФНАЦ ВИМ [59] было разработано программное обеспечение, способное накапливать информацию с диагностических устройств и бортовой системы трактора в базу данных для дальнейшего анализа с помощью искусственного интеллекта (нейронной сети), что исключает моделирование данных и имитацию повреждений, позволяя проводить обучение нейронной сети на реальных данных, повышая достоверность диагностирования. В рамках данного подхода наиболее распространённой архитектурой является сеть прямого распространения с механизмом прогнозирования (рисунок 1.13).

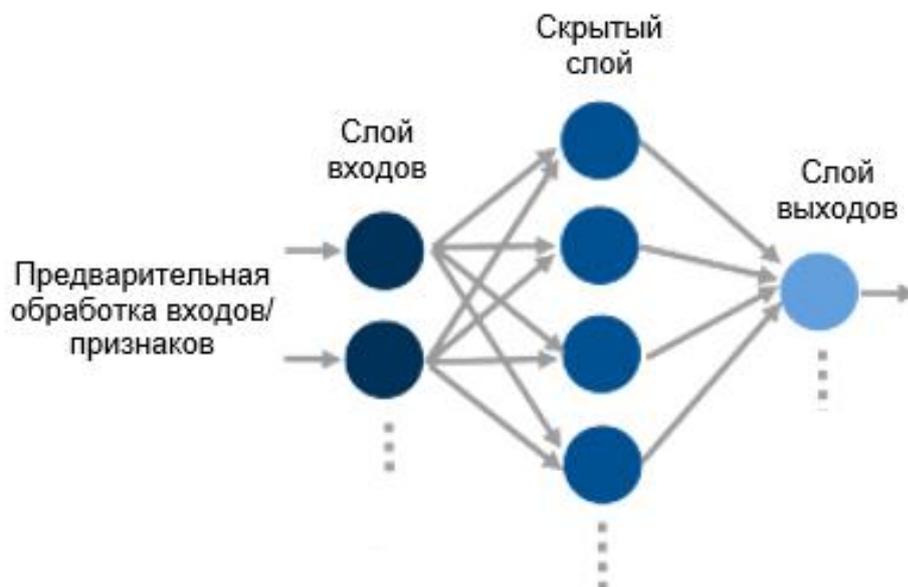


Рисунок 1.13 – Нейронная сеть прямого распространения

Метод конкурентных нейронных сетей основан на обучении нейронов распознаванию групп схожих входных векторов, при котором активируется только нейрон с наиболее близким весовым вектором к входному сигналу, что позволяет отображать различные состояния системы (исправное и дефектные) в виде отдельных кластеров на карте признаков. Наряду с нейросетевыми подходами, в задачах диагностирования применяются статистические методы классификации, такие как непараметрический алгоритм k -ближайших соседей, используемый для контролируемой классификации.

Методы диагностики, основанные на модели процесса, используют принцип аналитической избыточности [54, 55, 56]. Его суть заключается в сравнении реальных выходных сигналов контролируемой системы с выходными сигналами, полученными от её аналитической (нефизической) математической модели (рисунок 1.14) [54, 56, 60, 61]. Основываясь на этом принципе, процесс диагностики структурно делится на два последовательных этапа: генерацию остатков (расхождений между реальными и модельными сигналами) и последующий анализ этих остатков для оценки состояния системы.

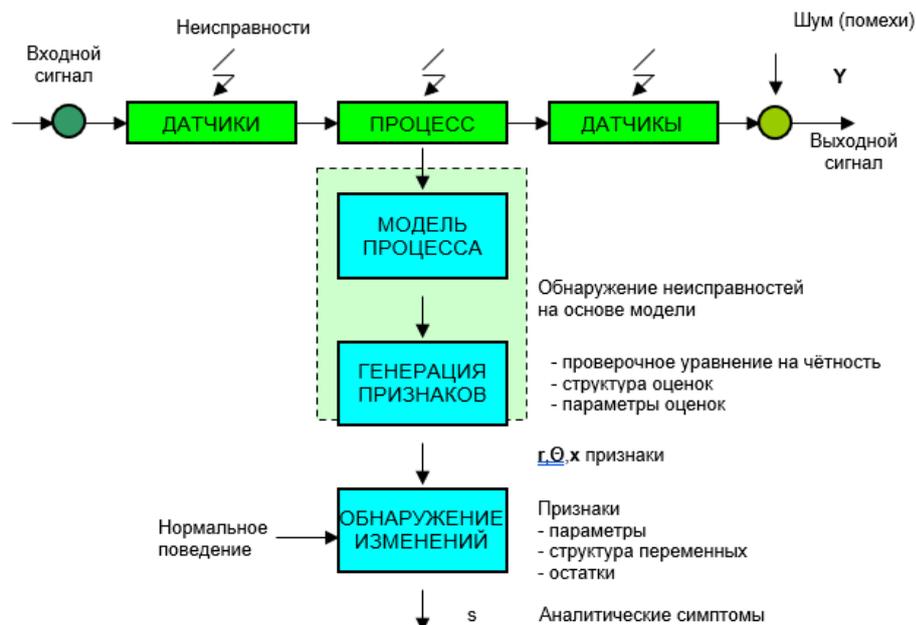


Рисунок 1.14 – Обнаружения неисправностей, основанные на модели процесса

Данный подход исходит из предположения о точной априорной известности структуры и параметров математической модели системы [54, 56]. В его рамках неисправности трактуются как изменения переменных состояния модели. Ключевым ограничением метода является его применимость преимущественно к линейным системам.

- Обнаружение неисправностей с проверочным уравнением на чётность

Этот метод основан на сравнении поведения реального технологического процесса с его математической моделью, описывающей номинальное (исправное) состояние системы [61]. Ключевая идея заключается в проверке соответствия (целостности) аналитических соотношений, выведенных из уравнений модели (отношений аналитической избыточности), фактическим измерениям с объекта. Рассогласование между сигналами реального процесса и моделируемыми сигналами формирует так называемый остаточный сигнал, или остаток, анализ которого используется для диагностирования (рисунок 1.15).

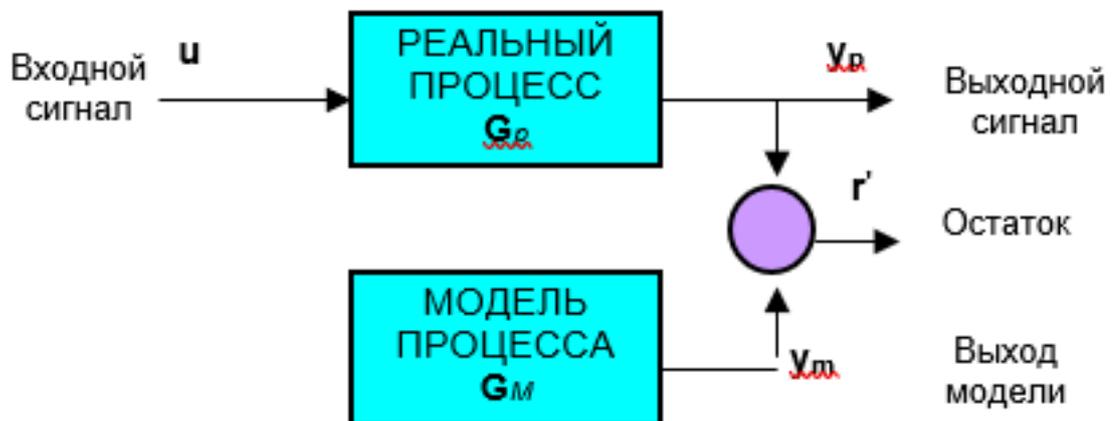


Рисунок 1.15 – Обнаружение неисправностей с проверочным уравнением на чётность

Процесс описывается передаточной функцией $G_p(s)$ и моделью процесса $G_M(s)$ [62]. Прямой метод, основанный на модели, заключается в принятии фиксированной модели G_M и запуске его параллельно с процессом, тем самым формируя ошибку на выходе

$$R'(s) = [G_p(s) - G_M(s)]u(s). \quad (1.29)$$

- Обнаружение неисправностей с наблюдением состояния и оценкой состояния

Изменения во входных и выходных параметрах процесса, вызванные неисправностью, приводят к изменениям в ошибке оценивания и переменных состояния системы [54, 55]. Суть подхода, основанного на наблюдении, заключается в реконструкции выходных сигналов системы с помощью наблюдателей, использующих доступные измерения. При этом оценка возникающей погрешности (так называемая инновационная последовательность или невязка) формирует диагностический остаток, применяемый для обнаружения неисправностей [61].

- Наблюдение состояния

Метод наблюдения состояния может быть применен, если неисправности могут быть смоделированы как изменение переменной состояния Δx_i . Конфигурация оценки линейного состояния полного порядка показана на рисунке 1.16 [55]. Она состоит из параллельной модели процесса (первая пара уравнений), с обратной связью (матрицы H) ошибки оценивания e [62].

$$X(t) = Ax(t)Bu(t) + He(t) \quad (1.30)$$

$$\hat{Y} = Cx \quad (1.31)$$

$$E(t) = y(t) - Cx(t) \quad (1.32)$$

$$R(t) = We(t) \quad (1.33)$$

e (в третьем уравнении), используется для расчёта остаточной r (четвёртое уравнение), с целью обнаружения неисправностей (например, с помощью пороговой логики).

- Наблюдение выхода

Задачей наблюдения состояния является восстановление состояния процесса. Тем не менее, в целом нет такой необходимости в диагностических целях. Можно использовать выходные наблюдения, если восстановление вектора состояния $x(t)$ не представляет интереса. Линейное преобразование с матрицей T_1 приводит к новому вектору состояния $a(t)$ [54]. Наблюдение

выхода реконструирует выходы для того, чтобы создать избыточность (рисунок 1.17) [54].

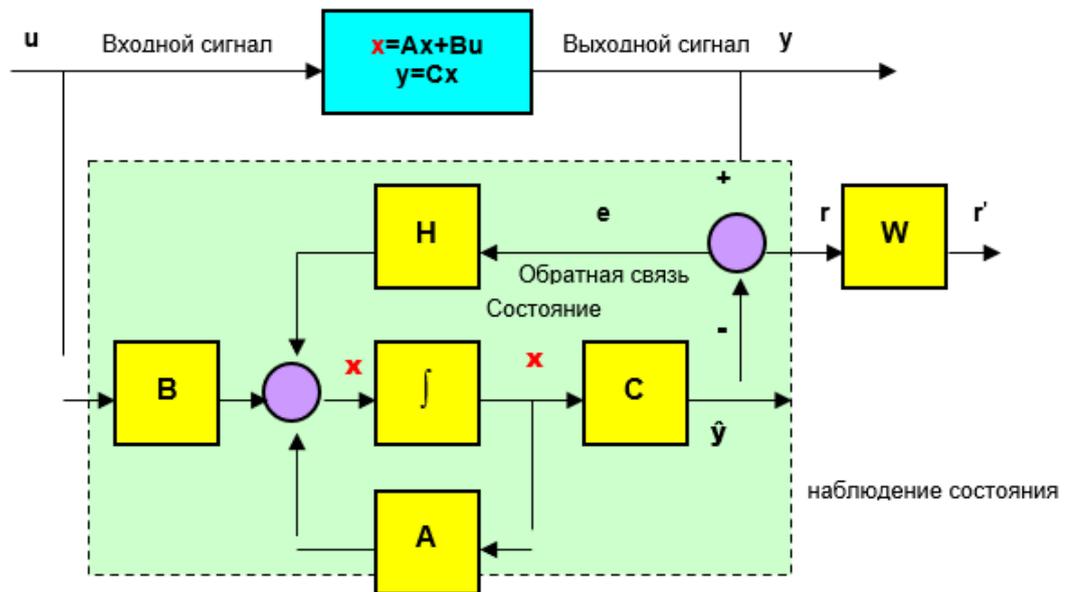


Рисунок 1.16 – Обнаружение неисправностей с наблюдением состояния

Уравнения наблюдений теперь изменены и представлены в виде:

$$\dot{\hat{a}}(t) = A_a \hat{a}(t) + B_a u(t) + H_a y(t) \quad (1.34)$$

$$\eta(t) = C_a \hat{a}(t) \quad (1.35)$$

$$a(t) = T_1 x(t) \quad (1.36)$$

$$r(t) = C_a a(t) - T_2 y(t) \quad (1.37)$$

$$C_a T_1 - T_2 C = 0. \quad (1.38)$$

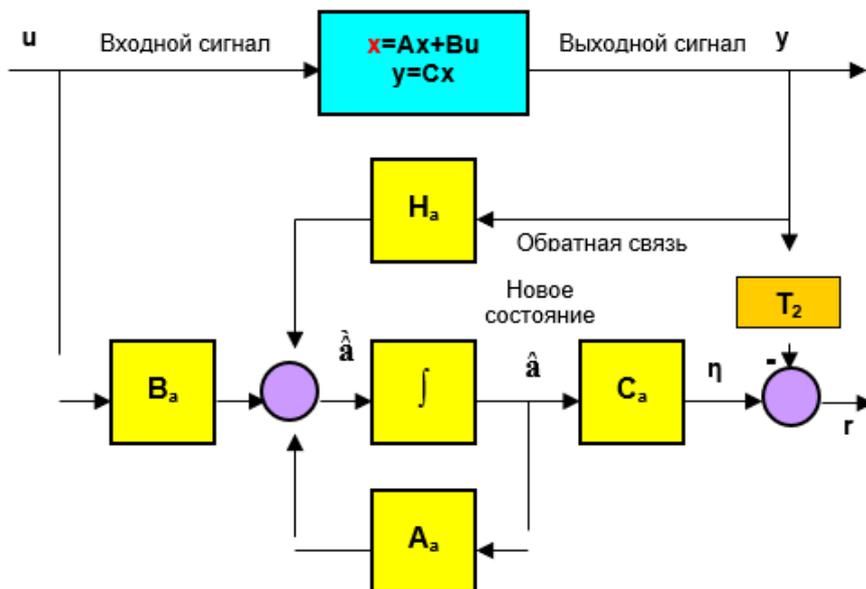


Рисунок 1.17 – Обнаружение неисправностей с наблюдением выхода

Метод проверочных уравнений на чётность и наблюдения состояния имеет аналогичные уравнения, но различаются в фильтрации остатка.

- Обнаружение неисправностей с оценкой параметров

В практических задачах параметры технологического процесса часто являются априорно неопределёнными. При известной базовой структуре модели их можно оценить методами параметрической идентификации, используя измеряемые входные и выходные сигналы. Поскольку неисправности динамической системы проявляются через изменения её физических параметров (таких как трение, масса, сопротивление, ёмкость, индуктивность), идея параметрического подхода (рисунок 1.18) состоит в обнаружении дефектов путём оценки этих параметров математической модели в соответствии со следующей процедурой [54, 55, 56]:

1. Выбор параметрической модели системы.

2. Определение взаимосвязи между параметрами модели θ_i и физическими параметрами p_i

$$\Theta = f(p). \quad (1.39)$$

3. Идентификация параметров модели вектора θ с использованием входа u и выхода y фактической системы.

4. Определение физических параметров вектора p

$$p = f^{-1}(\theta). \quad (1.40)$$

5. Расчёт отклонений вектора, Δp , от его номинального значения, взятого из номинальной модели.

6. Решение о неисправности путём использования взаимосвязей между неисправностями и изменениями в физических параметрах, Δp_i .

- Нелинейные модели и нейронные сети

Многие промышленные процессы не подходят для традиционных подходов к моделированию из-за отсутствия точных, формальных знаний о системе и значительного нелинейного поведения. В тех случаях, когда математические модели процесса G_p не доступны, для генерации остатков может быть использована нелинейная модель (рисунок 1.19). Одним из

способов построения нелинейной модели G_{NM} является использование нейронных сетей [54]. Нейронные сети не требуют специальных знаний о структуре процесса. Они могут служить в качестве модели чёрного ящика общих нелинейных многофакторных статических и динамических систем.

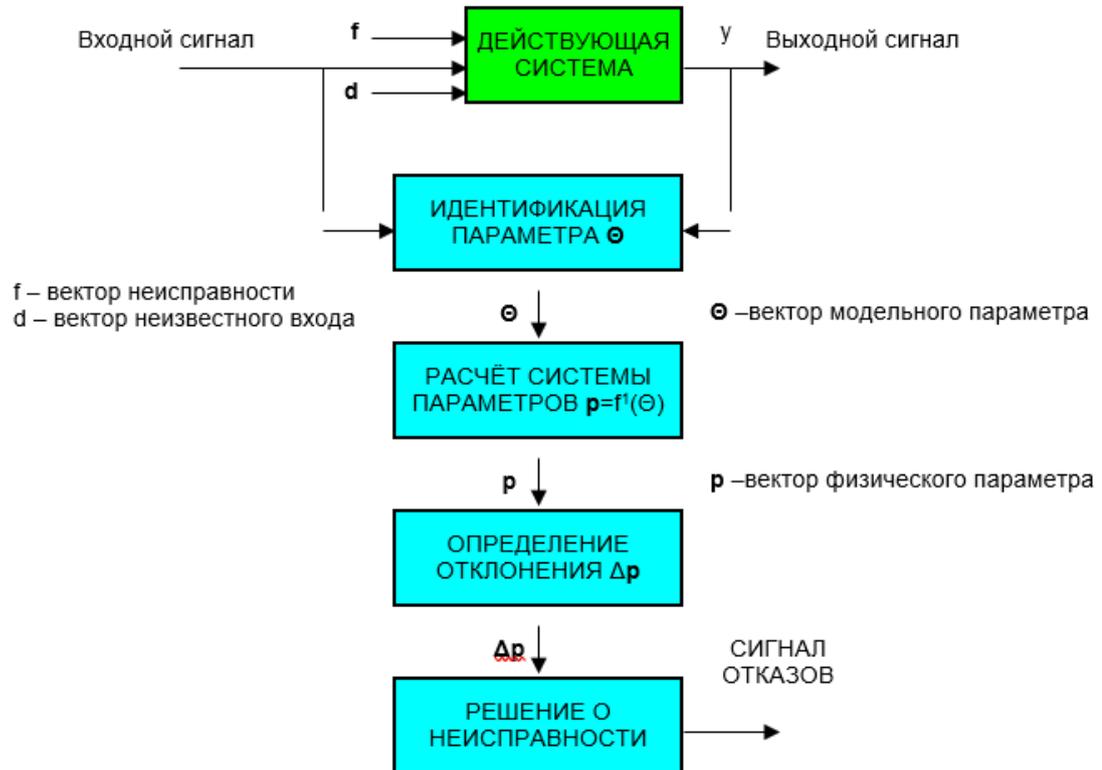


Рисунок 1.18 – Обнаружение неисправностей методом оценки параметров

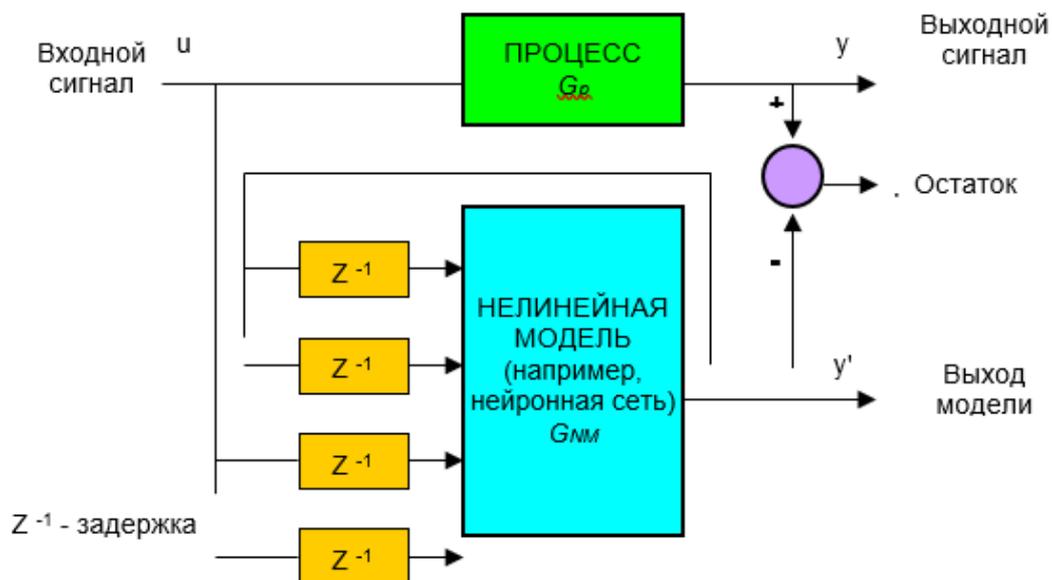


Рисунок 1.19 – Обнаружение неисправностей с использованием нелинейной модели и с проверочным уравнением на чётность

Несмотря на значительное количество внутренних параметров, нейронные сети, как правило, не обеспечивают их прямую физическую интерпретацию относительно моделируемой системы. Однако после завершения процедуры обучения такая сеть может быть использована для обнаружения неисправностей, например, путём интеграции в схему проверки на основе уравнений аналитической избыточности (уравнений чётности).

$$R'(s) = [G_p(s) - G_{NM}(s)]u(s). \quad (1.41)$$

Применение нейронных сетей в рамках модельно-ориентированного подхода к обнаружению неисправностей, интегрированное с методом проверки на основе уравнений аналитической избыточности (уравнений чётности), описано в работе [62].

Нейронные сети, применяемые для распознавания образов, также могут комбинироваться с различными моделями процесса и использоваться для анализа остаточных сигналов, как правило, после предварительной обработки этих остатков [63].

- Обнаружение неисправностей регулирующего контура

Автоматический контроль работы систем управления с обратной связью необходим для раннего обнаружения неисправностей. На крупных предприятиях, имеющих сотни регулирующих контуров, целесообразна реализация автоматизированных систем диагностирования. Появление неисправностей в таких контурах часто приводит к возникновению колебаний, поэтому важной задачей становится автоматическая идентификация различных типов колебательных процессов. Для этого применяются как методы, основанные на анализе сигнала (например, дисперсионные методы), так и модельно-ориентированные подходы.

Методы, основанные на знаниях. Как уже отмечалось ранее, в последнее время существует тенденция разработки и широкого использования методов, основанных на знаниях и искусственном интеллекте:

- Экспертные системы

Экспертные системы, основанные на продукционных правилах, широко применяются для решения диагностических задач в условиях, когда доступны эмпирические знания и опыт специалистов, но отсутствует детальное физическое описание системы или его получение экономически нецелесообразно. Данный подход эффективен для квазистатических систем, функционирующих в рамках фиксированного набора условий, и структурно включает два основных компонента: базу знаний и механизм логического вывода (рисунок 1.20). Знания в таких системах формализуются в виде правил вида «ЕСЛИ – ТО». Наиболее сложным этапом разработки экспертной системы является приобретение знаний, источником которых обычно служит опыт профильных специалистов, инженеров и операторов технологических установок. К преимуществам этого подхода относятся модульность (лёгкость добавления и удаления правил), возможность получения объяснений хода рассуждений, а также поддержка индуктивных и дедуктивных процедур. К числу недостатков относят узкую предметную ориентацию, плохую адаптацию к новым, не заложенным в базу знаний ситуациям, неспособность адекватно моделировать динамические, изменяющиеся во времени процессы, отсутствие способности к самообучению на ошибках, а также высокие затраты на разработку и сопровождение.

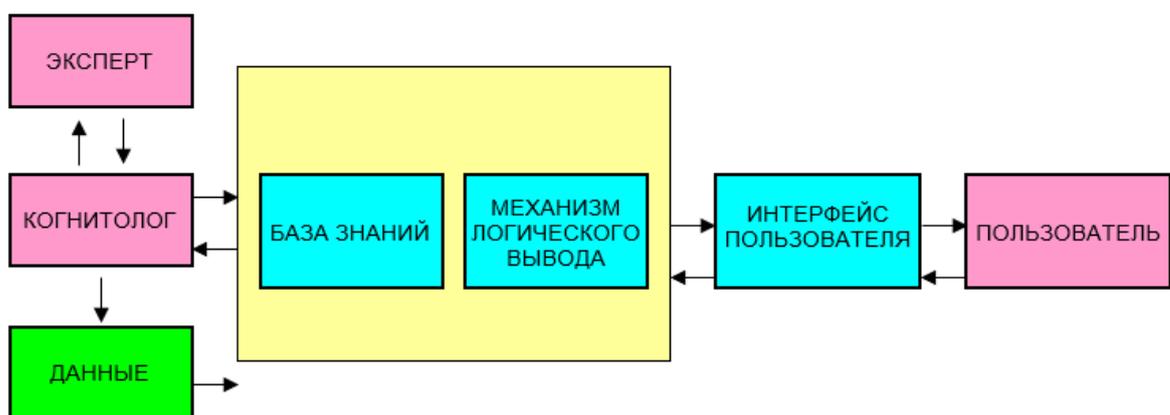


Рисунок 1.20 – Основные компоненты подхода экспертной системы

- Нечёткая логика

В отличие от систем, предоставляющих бинарный результат («неисправность» / «отсутствие неисправности»), современные системы диагностики могут оценивать и передавать оператору степень опасности обнаруженного отклонения, используя для этого выходные данные нечёткого регулятора. Лингвистически интерпретируемая модель, работающая на основе продукционных правил, синтезируется путем формализации экспертных знаний и анализа измеряемых параметров объекта [64, 65]. Структурная схема соответствующего нечёткого логического контроллера представлена на рисунке 1.21 [64].

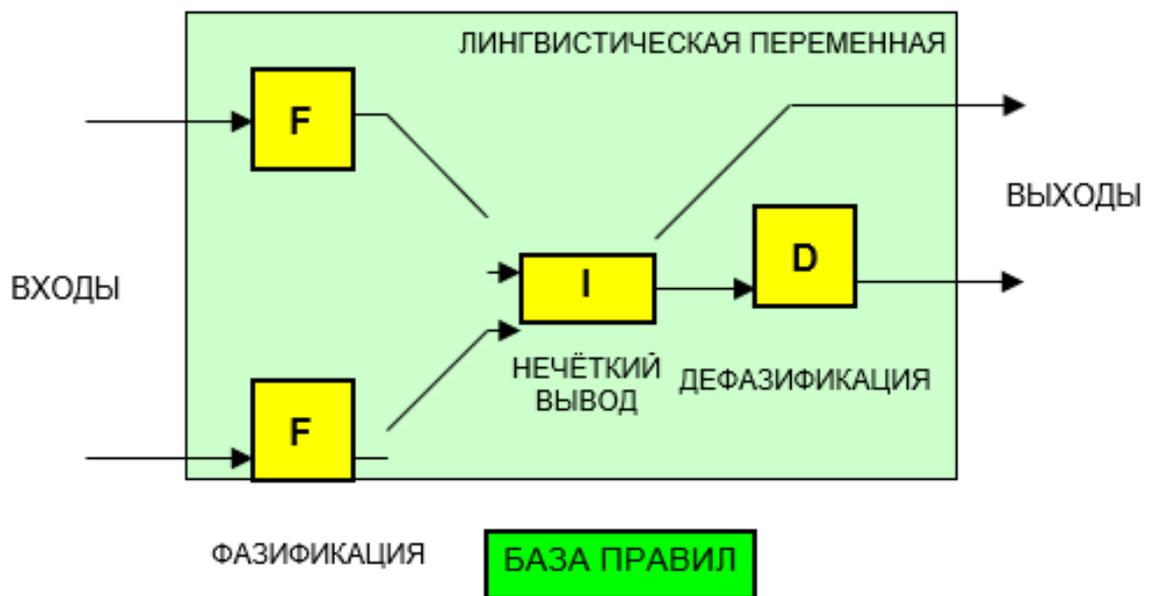


Рисунок 1.21 – Нечёткий логический контроллер

Нечёткий процесс вывода включает в себя следующие этапы:

1. Подготовка задачи для решения методами нечёткой логики (фазификация).

Входы в контроллер проходят через процесс фазификации с использованием функций принадлежности. Функция принадлежности представляет собой графическое представление величины участия каждого входа.

2. Правило логического вывода

Все правила оцениваются параллельно с использованием нечёткого рассуждения. Процесс нечёткого вывода использует функции принадлежности, логические операции и правила “если-то”.

3. Перевод уравнения нечёткой логики в фактическое числовое значение (дефаззификация)

Пример обнаружения неисправностей гидравлической установки с использованием комбинации нелинейного наблюдения и нечёткой логики дан в работе [75].

Вывод по первой главе

1. Проведен анализ современных технологий и методов диагностирования технических систем, в результате которого выявлена тенденция перехода от планово-предупредительного обслуживания к интеллектуальному мониторингу состояния в реальном времени. Обоснована ключевая роль вибродиагностики как наиболее информативного метода контроля состояния машин и оборудования.

2. Систематизированы методы обработки вибрационных сигналов (временной, частотный, частотно-временной анализ) и отбора диагностических признаков. Для условий нестационарных режимов и наличия шумов обоснована необходимость применения современных методов обработки (вейвлет-преобразование, эмпирическая модовая декомпозиция) и интеллектуального отбора признаков.

3. На основе проведённого анализа методов обработки вибросигналов предложен комплексный подход, включающий анализ спектральной плотности мощности, извлечения статистических и энергетических параметров и классификацию состояний основанный на адаптивных пороговых методов. Данный подход формирует основу для последующего анализа и разработки методов диагностирования конкретных технических систем.

В рамках проведенного анализа теоретических основ диагностирования технических систем определена цель дальнейших исследований:

Цель исследования – повышение эффективности эксплуатации сельскохозяйственной техники путем совершенствования методов вибродиагностирования гидравлических насосов.

Для достижения поставленной цели необходимо решение следующих задач:

1. Провести системный анализ, обзор и синтез современных методов диагностирования технических систем.

2. Разработать адаптивный алгоритм вибродиагностирования гидравлических насосов сельскохозяйственной техники, основанный на интеллектуальном отборе информативных признаков из вибрационного сигнала.

3. Разработать и экспериментально обосновать комбинированный метод вибродиагностирования для оценки технического состояния гидравлических насосов.

4. Разработать программный комплекс для автоматизированного вибродиагностирования с реализацией адаптивных алгоритмов анализа сигналов и интеллектуальной классификации дефектов гидравлических насосов.

5. Провести оценку точности разработанного программного комплекса для автоматизированного вибродиагностирования гидравлических насосов, установить и обосновать диагностические пороги для ключевых дефектов, дать рекомендации по использованию полученных результатов на предприятиях технического сервиса сельскохозяйственной техники АПК России.

6. Обосновать экономическую эффективность внедрения разработанного программного комплекса вибродиагностирования гидравлических насосов при эксплуатации сельскохозяйственной технике АПК России.

ГЛАВА 2. АНАЛИЗ МЕТОДОВ ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ СИСТЕМ

2.1 Интеллектуальные методы вибродиагностирования гидравлических систем машин и оборудования на основе сигналов

Методы диагностирования неисправностей разделяются на три категории: методы, основанные на режиме, знаниях и сигналах. Методы на основе моделей должны установить модель системы до постановки диагноза и включают оценку состояния, оценку параметров и эквивалентное пространство. Однако для гидравлической системы сложно создать модель из-за связи между различными переменными. Методы, основанные на знаниях, ориентированы на получении большого объёма экспертных знаний для моделирования процесса экспертных рассуждений определенной модели. Они подходят для ситуаций, в которых причина неисправности ясна, а логика принятия решения сильна [66]. Однако их низкая способность к постепенному обучению затрудняет добавление новых знаний в существующую систему, а изучение новых образцов будет происходить за счёт отказа от исходных знаний. Из-за динамической сложности гидравлической системы и отсутствия механизма ее отказа предварительных знаний недостаточно, что приводит к меньшему количеству исследований в этой области.

Сигнальные методы, используемые для диагностирования, основаны на сигналах состояния, таких как вибрации, звук, температура и давление. Если в системе есть неисправность, это должно быть отражено в сигнале. Следовательно, теоретически существенный признак неисправности может быть получен при условии надлежащего анализа признаков сигнала и надлежащего применения метода распознавания паттернов. Методы, основанные на сигналах, широко изучаются в интеллектуальном диагностировании неисправностей. Во-первых, они выигрывают от развития технологий датчиков и хранения данных, которые позволяют системе

мониторинга собирать и хранить большие объёмы автономных и онлайн-выборок сигналов. Вторая причина заключается в постоянных инновациях и высокой производительности, достигаемой алгоритмами машинного обучения. Машинное обучение [67] – это тип компьютерной программы, которая может постоянно получать новые знания и оптимизировать производительность на основе постепенного обучения. При использовании в диагностировании неисправностей, знания могут быть автоматически и самоадаптивно индуцированы и обобщены из полученных паттернов. Таким образом, это идеальная модель для извлечения признаков и распознавания паттернов.

Технологии интеллектуального вибродиагностирования неисправностей на основе сигналов включает обработку сигналов и выделение признаков. Извлечение признаков из сигнала крайне важно при диагностировании неисправностей, поскольку оно определяет результат последующего их распознавания. Различные типы сигналов, такие как звук, вибрация, температура и сигналы загрязнения масла [68], могут использоваться для отражения состояния техники. Одним из перспективных методов диагностирования гидравлических систем является вибрационный. Он позволяет определять техническое состояние элементов (деталей) по параметрам вибраций. Основными преимуществами выбранного метода являются: возможность производить диагностирование без разборки агрегата, высокая скорость определения неисправностей. Основным недостатком вибродиагностирования является высокая сложность обработки сигналов и выявления полезной, диагностической информации.

Исходный сигнал обычно необходимо разложить на несколько компонентов для устранения шума или разделения различных неисправностей. Типичные методы разложения показаны на рисунке 2.1. В основном это слепые методы разделения источников, такие как вейвлетная (пакетная) декомпозиция, сингулярная декомпозиция (СД), эмпирическая

модовая декомпозиция (ЭМД) и ансамблевая эмпирическая модовая декомпозиция (АЭМД).



Рисунок 2.1 – Процессы интеллектуального вибродиагностирования неисправностей на основе сигналов

Zhu и соавт. [69] предложили инвариантный к сдвигу метод разреженного кодирования слепого разделения источников, который использовался для извлечения пульсаций давления для гидравлических насосов и добился отличных результатов. Сосредоточившись на проблеме чувствительности ЭМД к шуму они предложили гибридный метод нелокальной средней декомпозиции. Однако результаты эксперимента показали, что вышеперечисленные методы не идеальны для гидроразрыва. Основная причина заключается в том, что одна и та же неисправность с разной степенью повреждения не обязательно имеет одинаковые частотные составляющие, а иногда даже генерирует новые признаки неисправности.

Далее необходимо выполнить обработку сигналов и выделение признаков. Цель обработки сигнала состоит в том, чтобы реализовать преобразование сигнала и выделение признаков. Извлеченные

характеристики, такие как временная область, частотная область, временная частота и статистические характеристики, будут использоваться для распознавания паттернов неисправностей.

Что касается сигнала вибрации генерируемый гидравлической системой, то из-за его нестационарных и сильно меняющихся во времени характеристик преобразование Фурье не может описать, как частота сигнала изменяется во времени. Goharrizi использовал преобразование Фурье для обнаружения утечек в гидравлическом цилиндре, хотя результаты оказались неудовлетворительными. Затем автор применил вейвлет и ЭМД для разложения сигналов гидравлической вибрации. Кроме того, оконное преобразование Фурье (ОПФ) было предложено Gabor в 1946 году. На основе исходного преобразования Фурье во время преобразования используется скользящее окно, которое может реализовать локализацию локальных частотных характеристик. Ограниченный принципом неопределённости Гейзенберга, оно не может одновременно обеспечивать высокое разрешение во временной и частотной областях.

Распределение Вигнера-Вилля (РВВ) обладает хорошими свойствами математических операций. При использовании для анализа нестационарного сигнала в большинстве случаев демонстрируется хорошая производительность. Однако РВВ имеет недостаток – между различными частотными компонентами будут генерироваться перекрестные помехи. При использовании для обнаружения неисправностей гидравлических систем, таких как кавитация и составная неисправность, он не может успешно извлечь частотные характеристики.

Вейвлет-преобразование наследует идею локализации кратковременного преобразования Фурье (КПФ). В то же время он обеспечивает частотно-временное окно, которое может автоматически и адаптивно изменяться в зависимости от частоты. Благодаря операциям расширения и Вейвлет-преобразование может реализовать высокое частотное разрешение на низких частотах и высокое временное разрешение на высоких

частотах, что позволяет легко сосредоточиться на деталях сигнала [70]. Таким образом, это инструмент для частотно-временного анализа сигнала. Однако выбор основы вейвлета оказывает существенное влияние на результаты частотно-временного преобразования [71]. Различные вейвлеты подходят для анализа различных частотно-временных характеристик.

Чтобы повысить достоверность диагностирования оборудования, работающего в шумной среде, исследователи попытались объединить несколько методов выделения признаков и объединить их результаты в качестве основы для диагностирования. Когда различные признаки объединяются, формируется многомерный вектор, что приведёт к потреблению большого количества вычислительных ресурсов. В то же время не все признаки имеют одинаковый вклад и корреляцию с диагностикой неисправности. Поэтому требуется уменьшение размерности и разреженное представление. Как было показано на рисунке 2.1, основные изучаемые методы включают анализ основных компонентов (АОК), анализ независимых компонентов (АНК) и линейный дискриминантный анализ (ЛДА). Все перечисленные методы основаны на гипотезе о том, что выборки подчиняются распределению Гаусса (АОК) или линейной модели (АНК или ЛДА). Тем не менее, реальные вибрационные сигналы обычно не удовлетворяют этим условиям. Следовательно, для решения этой проблемы были представлены некоторые ядерные методы, такие как анализ основных компонентов ядра (АОКЯ) и линейный дискриминантный анализ ядра (ЛДАЯ). Они используют функцию ядра для преобразования данных из одного пространства в другое, чтобы упростить извлечение нелинейных признаков.

Распознавание паттернов неисправностей.

Машинное обучение (МО) является многообещающим и широко исследуемым алгоритмом классификации благодаря его способности к адаптивному и поэтапному обучению. Среди них искусственная нейронная сеть – ИНС и метод опорных векторов (МОВ) являются двумя наиболее типичными классификаторами.

В области диагностирования неисправностей наиболее изученные включают сеть обратного распространения (СОР), сеть радиальной базисной функции (РБФ), автоассоциативную нейронную сеть (ААНС), сеть Хопфилда (Hopfield network), отображение самоорганизации (ОСО) сеть и машина Больцмана (Boltzmann machine). Чтобы преодолеть склонность следовать локальному оптимуму, ученые предложили множество новых методов, таких как сеть с эхо-состоянием (СЭС) [72], вероятностная нейронная сеть (ВНС) [73] и нейронная сеть с нечёткой логикой (НСНЛ) [74]. Что касается сложных проблем классификации, существует множество узких мест, которые ограничивают улучшение производительности ИНС. Одной из основных причин этого является переобученность из-за очень строгой цели обучения. При отсутствии предварительных знаний (опыта) трудно определить, какая цель обучения является наиболее подходящей.

МОВ использует функцию ядра внутреннего продукта вместо нелинейного отображения в многомерное пространство. Следовательно, по сравнению с ИНС, он демонстрирует многочисленные уникальные преимущества в решении нелинейных задач распознавания паттернов высокой размерности, особенно когда количество выборок невелико. Поэтому он широко изучался в области диагностирования неисправностей [75, 76]. Исследователи предложили много улучшенных версий МОВ для конкретных диагностических задач, таких как МОВ ядра Гаусса, МОВ оптимизации роя частиц (ОРЧ-МОВ) и АЭМД-МОВ [77]. Однако применение МОВ для интеллектуального диагностирования неисправностей гидравлической системы ограничено. Одна из причин этого заключается в том, что при столкновении с крупномасштабными обучающими выборками обучение МОВ выполнить сложно. Однако интеллектуальное диагностирование всегда основывается на онлайн-мониторинге, и неизбежно применяется большое количество паттернов. Во-вторых, МОВ не подходит для задачи множественной классификации. С увеличением сложности системы, если

также учитывать суперпозицию неисправностей и степень повреждения, неизбежно существенное увеличение количества видов неисправностей.

В дополнение к ИНС и МОВ, другие алгоритмы машинного обучения [78], включая логистическую регрессию, дерево решений, скрытую модель Маркова и байесовскую сеть, применялись для распознавания паттернов неисправностей и получили интересные достижения.

По мере усложнения конструкции гидрооборудования его функциональные возможности также становятся более мощными и повышается уровень его автоматизации, что требует большей надежности гидросистемы.

Технология диагностирования неисправностей гидравлической системы постоянно развивается и обновляется, и постепенно сформировалась всеобъемлющая дисциплина, объединяющая гидравлическое управление, датчики, теорию принятия решений, статистическую математику, обработку сигналов, искусственный интеллект и распознавание паттернов. Можно выделить следующие три стадии развития:

(i) Субъективный диагноз;

Метод субъективного диагностирования основан на том, что технический персонал получает информацию о состоянии гидравлического оборудования посредством прямого наблюдения или простого диагностического прибора. Были обобщены многие практические методы диагностирования, включая сенсорное диагностирование, инструментальное обнаружение, измерение параметров, метод замены компонента, метод разборки компонента, анализ логической цепи, теорию графов, анализ дерева отказов и метод деления на секции. Хотя метод субъективного диагностирования обеспечивает простоту, быстроту и практичность, он слишком сильно зависит от практического опыта и личных профессиональных способностей обслуживающего персонала. Он имеет ограниченные диагностические возможности для сложных гидравлических систем, а процесс разборки и сборки гидравлического повышает простота техники.

(ii) Диагностирование неисправностей гидросистемы на основе технологии обработки сигналов и математической модели;

С развитием технологии обработки сигналов и более быстрыми компьютерными вычислениями в области диагностирования появилось множество математических моделей и методов обработки сигналов. Метод диагностирования гидравлических неисправностей, основанный на технологии обработки сигналов, извлекает соответствующие характеристики путём измерения параметров и описывает соответствующую взаимосвязь между измеренными сигналами и неисправностями с помощью математической модели для постановки диагноза. В основном это включает анализ во временной области, анализ в частотной области, частотно-временной анализ, оценку состояния и оценку параметров. Например, Goharrizi и Sereshi [79] использовали вейвлет-преобразование для анализа сигнала вибрации гидравлического насоса, сигнала давления гидроцилиндра и гидропривода соответственно.

Применяемый тип диагностирования неисправностей гидравлических систем компенсирует неэффективность применения статистических данных вручную за счёт применения объективного измерения параметров и преимуществ компьютерной обработки сигналов. Благодаря возможности идентификации математической модели такая диагностика достигла хороших результатов применения в инженерных областях. Однако гидравлическая система является нелинейной, изменяющейся во времени системой, которая имеет определенные недостатки, такие как сложность выделения признаков, создание сложной математической модели и другие факторы.

(iii) Диагностирование неисправностей гидравлической системы на основе искусственного интеллекта;

Технология диагностирования неисправности гидравлической системы, которая использует метод распознавания паттернов искусственного интеллекта (ИИ) в качестве основной части и сочетает в себе различные методы извлечения признаков, доминирует в центре внимания и тенденции

развития в этой области. Saeed и соавт. [80] объединили АОК, ИНС и мультиадаптивную нейро-нечёткую систему логического вывода для диагностики неисправностей гидравлического трубопровода.

Lu [81] проанализировал и диагностировал сигналы вибрации гидравлического насоса, комбинируя метод ЭМД с нечётким кластерным анализом С-средних. Chaі и соавт. [82] использовал АОК для работы с различными частотно-временными характеристиками, а затем применил модель обучающую машину для диагностирования неисправности в гидравлической системе.

2.2 Анализ методов вибродиагностирования неисправностей гидравлических насосов машин и оборудования

Гидравлические системы являются основным силовым элементом большинства современных технологических машин, включая широкий парк сельскохозяйственной техники. Эти системы обеспечивают выполнение критически важных операций – от подъема навесного оборудования и поворота рулевых механизмов до привода рабочих органов посевных и уборочных агрегатов. Надежность гидравлики обеспечивает бесперебойность технологических циклов в растениеводстве, где простои техники в периоды посевной или уборочной кампании ведут к критическим нарушениям сроков выполнения агротехнических задач и как следствие, значительным экономическим потерям. Центральным элементом такой системы является гидравлический насос, преобразующий механическую энергию в энергию потока рабочей жидкости и обеспечивающий её подачу под давлением. Выход насоса из строя способен вызвать длительную остановку управляемого оборудования, что приводит к снижению производительности, экономическим убыткам, проблемам безопасности, а в критических случаях к аварийным ситуациям [83]. В связи с этим диагностирование неисправностей гидравлических насосов имеет высокую практическую значимость.

В соответствии с различными конструкциями гидравлические насосы можно разделить на гидравлические насосы шестеренного типа, гидравлические насосы лопастного (пластинчатого) типа, гидравлические насосы поршневого типа и гидравлические насосы винтового типа. Их принцип работы основан на переносе энергии путем перемещения замкнутых объемов жидкости из полости всасывания в полость нагнетания. Вращение вала приводит в движение рабочие органы насоса, которые, перемещаясь, последовательно захватывают жидкость в зоне всасывания. Переноса ее вдоль корпуса, они затем вытесняют в напорную линию. Ключевым моментом является то, что именно сопротивление в напорной линии препятствует вытеснению жидкости, что и приводит к росту давления в системе. Таким образом, насос создает поток, а давление формируется нагрузкой

В процессе эксплуатации в нормальном режиме компоненты гидравлического насоса подвергаются износу; аналогично, работа в нештатных условиях может провоцировать возникновение характерных признаков неисправностей, среди которых повышенный уровень шума и вибрации, снижение расхода рабочей жидкости и падение объёмного КПД. Поскольку отказ гидравлического насоса в целом чаще всего является следствием критического износа или повреждения отдельных его конструктивных элементов, исследование и диагностирование общей работоспособности системы может основываться на детальном анализе состояния ключевых компонентов.

Вал гидравлического насоса, ответственный за передачу вращательного движения и привод всей рабочей среды, представляет собой один из ключевых объектов диагностических исследований. В работе Ху и соавт. [84] причина разрушения вала была исследована путём расчёта радиальной силы в шестеренном насосе с последующей верификацией посредством конечно-элементного моделирования в программном комплексе ANSYS. Qin и соавт. [85] использовали ускоренные испытания на износ для анализа повреждения вала шестеренного насоса, проверили статическую прочность разрушенной

области и установили основные факторы, приведшие к отказу. Yordanov B. и соавт. [86] на основе металлографического и фрактографического анализа различных участков вала выявили смешанный характер морфологии разрушенной поверхности и пришли к выводу, что окисление поверхности и межзёрная коррозия на границах кристаллитов стали одной из причин зарождения и развития трещин.

В гидравлическом насосе есть неисправности, вызванные другими деталями и гидравлическим маслом. Pflum и соавт. [87] использовали датчик давления для обнаружения сигнала в узкополосной частотной области для анализа выкрашивания механического подшипника гидравлического насоса и отказа гидравлического шестеренного насоса. Wang и соавт. [88] провели испытание на виброусталость взрывонепроницаемого корпуса регулятора гидронасоса и проанализировали факторы, вызвавшие отказ корпуса.

Концепция диагностирования неисправностей гидравлического насоса на основе сигналов состояния предполагает сбор данных с помощью датчиков, последующую предварительную обработку полученных сигналов методами анализа (такими как спектральная обработка или фильтрация) и последующее применение специализированной диагностической модели для классификации состояния. В рамках исследования, при условии корректного сбора данных, методы диагностирования можно систематизировать в три следующие категории:

- (1) диагностирование неисправностей по одному сигналу;
- (2) диагностирование неисправностей на основе мультисигнала;
- (3) другие методы диагностирования.

Диагностирование неисправности на основе одиночного сигнала

В современных диагностических системах, основанных на анализе единичного сигнала, вибрационный сигнал является наиболее перспективным видом входных данных для модели. Это обусловлено тем, что возникновение дефектов во внутренних компонентах насоса закономерно изменяет его нагрузочные и структурно-динамические характеристики, что

непосредственно отражается на вибрационном отклике конструкции. Регистрируя сигналы вибрации и применяя методы их обработки, можно извлечь информацию о конкретных неисправностях, после чего выполнить диагностирование с использованием алгоритмов искусственного интеллекта или специализированных методов анализа сигналов. Параллельно развиваются подходы, использующие иные типы сигналов мониторинга, такие как акустические сигналы.

Диагностирование неисправностей на основе сигнала вибрации

В методах диагностирования неисправностей гидронасоса можно выделить две основные категории:

(1) Метод, основанный на обработке сигналов;

Было доказано, что сигнал вибрации полезен для диагностирования неисправностей гидравлических насосов, но он содержит шум, помехи и другую информацию без характеристик неисправности. Следовательно, необходимо использовать эффективные методы обработки сигналов для извлечения имеющейся информации о неисправностях из сигналов вибрации.

Yu и соавт. [89] предложили метод, основанный на эмпирическом вейвлет-преобразовании и анализе весовых коэффициентов разреженности компонент, для работы с нелинейными, многочастотными и зашумленными данными вибрационных сигналов. Li Z. и соавт. [90] использовали комбинацию ансамблевой эмпирической модовой декомпозиции и анализа парных корреляций для шумоподавления собранных сигналов вибрации гидравлического насоса, преобразовали очищенные данные в изображения с использованием метода симметричных полярных координат, а затем преобразовали полученные изображения в матрицу совпадения уровней серого и использовали алгоритм нечетких C-средних для диагностики неисправностей.

В условиях эксплуатации информативность данных о зарождающихся неисправностях гидравлических насосов часто оказывается недостаточной, что требует разработки методов диагностирования в условиях дефицита

информации. Для решения проблемы низкой эффективности обнаружения ранних дефектных сигналов, Yu и соавт. [89] предложили метод, основанный на эмпирическом вейвлет-преобразовании для декомпозиции трёхканальных вибрационных сигналов с последующим вычислением весовых коэффициентов разреженности для селекции компонент и демодуляцией характеристической частоты с помощью преобразования Гильберта.

Методы диагностирования гидравлических насосов, основанные исключительно на обработке сигналов, обладают рядом принципиальных ограничений. Анализ во временной области склонен давать некорректные оценки при серьёзных неисправностях со значительной случайной составляющей и неприменим для нестационарных сигналов. Частотный анализ, в свою очередь, не отражает временную динамику сигнала и обладает низкой чувствительностью к зарождающимся дефектам. Подходы, основанные на слиянии данных от множества датчиков, сталкиваются с проблемами сложности конфигурирования измерительной системы, управления ею, а также разработки алгоритмов интеграции диагностической информации.

(2) Методы на основе искусственного интеллекта

Несмотря на эффективность методов обработки вибрационных сигналов в извлечении и визуализации информации о неисправностях гидравлических насосов, их быстроедействие и точность остаются недостаточно высокими. Однако развитие технологий искусственного интеллекта обеспечивает появление множества интеллектуальных алгоритмов и моделей, способных осуществлять эффективное диагностирование, а присущая им способность к самообучению значительно повышает точность работы. Таким образом, наиболее эффективным представляется комплексный подход, который сочетает метод обработки сигналов (ориентированный на выделение диагностических признаков из вибрации) с алгоритмами и моделями искусственного интеллекта для окончательной классификации неисправностей.

- ① *Метод искусственного интеллекта на основе нейронной сети;*

Благодаря свойству нейронных сетей к обобщению данных, модели на их основе находят всё более широкое применение в диагностировании неисправностей гидравлических насосов. Полносвязные нейронные сети, в частности, обладают способностью к самообучению и высокоскоростному поиску оптимальных решений, что обеспечивает высокие точность и скорость диагностирования. Например, Gao и соавт. [92] разработали метод, сочетающий эмпирическую модовую декомпозицию (ЭМД) и нейронную сеть.

- ② *Метод искусственного интеллекта на основе метода опорных векторов;*

Метод опорных векторов (МОВ), основанный на принципах статистической теории обучения, может применяться для решения задач классификации и регрессии в рамках обучения с учителем, без учителя и при частичном привлечении размеченных данных, демонстрируя высокую эффективность как для линейных, так и для нелинейных сигналов. Tian и соавт. [93] предложили подход к выделению признаков износа, основанный на инкрементальном анализе локальных характеристик износа с применением медианного фильтра, после чего эти признаки подавались на вход модифицированного метода опорных векторов, организованного по принципу бинарного дерева, для выполнения диагностики.

- ③ *Метод искусственного интеллекта на основе предельной обучающейся машины;*

Предельная обучающаяся машина сопоставляет входные данные объекта со случайным пространством, а затем использует линейную регрессию наименьших квадратов. Её преимущества заключаются в том, что скрытый слой не требует повторения, скорость обучения высокая, а производительность обобщения хорошая. Ding и соавт. [94] разработали метод диагностирования неисправностей, сочетающий (ЭВП), метод обработки

сигналов АОК и обучающую машину. Lan и соавт. [95] предложили интеллектуальный метод диагностирования неисправностей для гидравлических насосов на основе вейвлет-пакетного преобразования, ЭМД, технологии множественной обработки сигналов ЛМД и технологии идентификации обучающей машиной.

Подход, основанный на нейронных сетях, реализует диагностирование путём извлечения признаков из обработанных сигналов и использования сети в качестве модели, которая выполняет нелинейное отображение признаков на соответствующие причины неисправностей. Однако процесс принятия решения в таких моделях часто остаётся неинтерпретируемым, что снижает прозрачность и объяснимость диагноза. В качестве альтернативы может применяться метод нечётких рассуждений, который эффективно работает с неточной и неполной информацией, характерной для диагностирования насосов. Его основными ограничениями являются трудность формирования исчерпывающей базы правил и функций принадлежности, а также низкая способность к самостоятельному обучению.

Диагностирование неисправностей на основе других сигналов;

Для расширения возможностей диагностирования гидравлических насосов, помимо анализа вибрации, могут применяться и другие типы сигналов мониторинга, такие как акустические. Использование новых видов сигналов требует разработки соответствующих методов обработки, что способствует разнообразию диагностических подходов. Например, в работе [69] предложен метод диагностирования на основе анализа звукового сигнала с применением скрытых марковских моделей (АОКЯ), что актуально в случаях, когда установка вибродатчиков затруднена или методы обработки вибрации недостаточно эффективны. В исследовании [67] для диагностирования аксиально-поршневого насоса используется комбинация мел-кепстральных коэффициентов, извлечённых из акустического сигнала, и алгоритмов машинного обучения, где эти коэффициенты выполняют функцию

уникального "голосового отпечатка" для построения классификационной модели.

Для диагностирования неисправностей гидравлических насосов применяются разнообразные подходы, использующие различные типы сигналов. Tang и соавт. [98] предложили метод, основанный на анализе сигнала давления: частотно-временные характеристики, полученные с помощью непрерывного вейвлет-преобразования (НВП), подавались на вход адаптивной глубокой сверточной нейронной сети (СНС), гиперпараметры которой оптимизировались байесовским методом. Другой подход, также использующий сигнал давления, был реализован Wang и соавт.: с помощью метода конечных элементов и модальной декомпозиции сигнал разлагался на компоненты, после чего для выделения диагностической информации применялся анализ относительной энтропии, обеспечивающий также эффективное подавление шума. Для работы в нестационарных условиях Wang и соавт. [99] разработали метод диагностирования, основанный на анализе сигнала мгновенной угловой скорости (МУС), полученного методом равных углов.

Четыре основные неисправности гидравлических насосов, связанные с износом, обобщенные в литературных исследованиях, классифицируются как неисправность I: неисправности, связанные с износом при трении; Неисправность II: неисправность абразивного износа; Неисправность III: дефект ямочного износа; Неисправность IV: коррозионный износ. Кроме того, он дополнительно оценивает статью по следующим пунктам:

- Индекс I: улучшить характеристики неисправности;
- Индекс II: оптимизация алгоритма диагностирования неисправности;
- Индекс III: адаптироваться к сильному шуму;
- Индекс IV: высокая точность диагностирования.

Диагностирование неисправностей на основе нескольких сигналов

Информация о неисправности, содержащаяся в текущей обработке одиночного сигнала, ограничена. Чтобы увеличить сбор информации о

неисправностях, характеристические сигналы нескольких сигналов могут содержать больше информации о неисправностях более высокого порядка, что способствует повышению точности диагностирования неисправностей гидравлических насосов и внедрению более инновационных способов обнаружения неисправностей гидравлических насосов.

(1) Метод, основанный на обработке сигналов;

Диагностирование гидравлических насосов на основе множества сигналов предполагает отдельную обработку каждого входного параметра с последующим интегрированием полученной признаковой информации специальными алгоритмами слияния данных, что позволяет сформировать достаточную информационную базу для определения состояния. Например, Liu и соавт. [100] разработали метод диагностирования шестеренных насосов, комбинирующий адаптивную эмпирическую модовую декомпозицию (АЭМД) с байесовской сетью, что позволяет комплексно использовать информацию из нескольких источников, выходя за рамки традиционного анализа только сигналов датчиков. Vuïges и соавт. [101] использовали для диагностирования сравнение сигналов ускорения, энергопотребления, расхода и давления с их эталонными значениями, характерными для нормального режима. Przystupa и соавт. [102] исследовали возможность диагностирования путём анализа спектров и автокорреляционных функций (АКФ) сигналов давления и расхода с применением БПФ для различных условий эксплуатации. Ma Z. и соавт. [103] предложили статистический байесовский метод диагностирования, основанный на модели обратного гауссова процесса с переменной скоростью для описания износа и анализе данных о падении давления и расхода.

(2) Методы на основе искусственного интеллекта;

Подобно интеллектуальным методам, описанным выше, метод диагностирования неисправности многосигнального гидравлического насоса делится на метод на основе нейронной сети, метод на основе классификатора и метод на основе обучения миграции.

- *①Метод искусственного интеллекта на основе нейронной сети;*

В структуре нейронных сетей количество нейронов во входном слое часто превышает единицу, поэтому многосигнальный вход совместим с многовходовыми характеристиками входного слоя нейросетевой структуры.

Свёрточная нейронная сеть превзошла возможности человеческого глаза по точности распознавания изображений, поэтому цифровой сигнал гидравлического насоса может быть преобразован в сигнал изображения для свёрточной нейронной сети для диагностирования неисправности гидравлического насоса. Tang и соавт. [104] предложили интеллектуальный метод диагностирования неисправностей, основанный на адаптивной скорости обучения нейронной сети, для диагностирования различных типов неисправностей с использованием НВП для преобразования трех исходных сигналов: сигнала вибрации, сигнала давления и звукового сигнала в двумерные частотно-временные изображения и использования стратегии адаптивной скорости обучения для создания улучшенной модели глубокой СНС. В качестве объектов анализа взяты сигналы вибрации и давления гидронасосов. Jiang и соавт. [105] разработали алгоритм диагностирования неисправностей для гидравлических насосов на основе ЭВП и одномерной СНС и развернули одномерную модель СНС на облачной платформе для диагностирования неисправностей в реальном времени на основе облачной платформы. На основе одномерных входных сигналов также используется высокоточная структура нейронной сети для повышения точности диагностирования неисправностей гидравлического насоса. Нейронная сеть использует стратегию линейной оптимизации, обладает высокой скоростью обучения и может приближаться к любой нелинейной функции с произвольной точностью. Zuo и соавт. [106] разработали метод диагностики неисправности гидравлического насоса на основе нейронной сети, который использует сигнал вибрации корпуса насоса и импульсный сигнал давления на выходе насоса в качестве входных характеристик.

- ② *Подход на основе классификатора;*

Функция классификатора состоит в том, чтобы классифицировать хаотические цели по разным категориям в соответствии с разными входными сигналами. При диагностировании гидравлических насосов неисправности, отображенные на входном сигнале, могут быть классифицированы классификатором для определения неисправностей. Jiang и соавт. [107] использовали дерево решений для построения модели случайного леса, обучили шесть непрерывных переменных системы гидравлического винтового насоса в качестве входных характеристик и построили метод диагностирования неисправностей гидравлического насоса на основе модели случайного леса. Ну и соавт. [108] построил систему диагностирования множественных отказов на основе слияния данных в соответствии с теорией свидетельств Демпстера-Шафера и использовали динамическую марковскую модель для построения функции диагностики отказов с базовой функцией распределения вероятности, обеспечивающей объективность оценки распределения надежности.

- ③ *Методы, основанные на трансфертном обучении;*

Чтобы обобщить возможности модели, параметры обученной модели можно перенести в новую модель, чтобы помочь в обучении, что может повысить производительность инициализации модели, ускорить скорость продвижения и улучшить сходимость. Miao и соавт. [109] использовали комплексную ансамблевую ЭМД и сингулярное разложение для разложения сигнала давления, сигнала вибрации и сигнала расхода для построения векторов характеристик и построили метод диагностирования неисправностей гидравлического насоса с помощью алгоритма обучения миграции TrAdaBoost..

Другие методы диагностирования неисправностей;

Независимо от того, основаны ли они на обработке сигналов или искусственном интеллекте, они используют метод диагностирования

неисправностей гидравлических насосов на основе данных. Этот метод реализует диагностирование неисправностей гидравлического насоса с использованием отношения отображения между цифровым сигналом и неисправностью и не описывает подробно функцию механизма неисправности. В некоторых исследованиях были предложены новые знания или концепции, основанные на взаимосвязи между нецифровой сигнальной информацией и картированием неисправностей гидравлического насоса.

На основе ускоренного жизненного цикла Guo и соавт. [110] предложили технологию динамической сетки для детального моделирования поля внутреннего потока гидравлических насосов. На основе анализа толщины пленки Miao и соавт. [109] предложили метод диагностирования гидравлического насоса, основанный на анализе модели упругогидродинамической смазки путём всестороннего учета структурных параметров, параметров рабочего состояния и параметров характеристик материала. Ввиду многократных трещин шестерни гидравлического шестеренного насоса Zhao и соавт. [111] установили формулу расчета конечных элементов вибрационного вейвлета для сплошной шестерни и шестерни с трещинами, изучили диагностирование неисправностей алгоритма разделения слепых источников и оптимизации роя частиц, а также правильно диагностировали расположение множественных трещин шестерни.

Основываясь на методах диагностирования неисправностей, рассмотренных в приведенной выше литературе, можно предложить следующую блок-схему диагностирования неисправностей, как показано на рисунке 2.2. Поскольку существует много типов методов диагностирования, и многие из них расширяют базовые методы, здесь включены только основные методы диагностирования неисправностей гидравлического насоса.

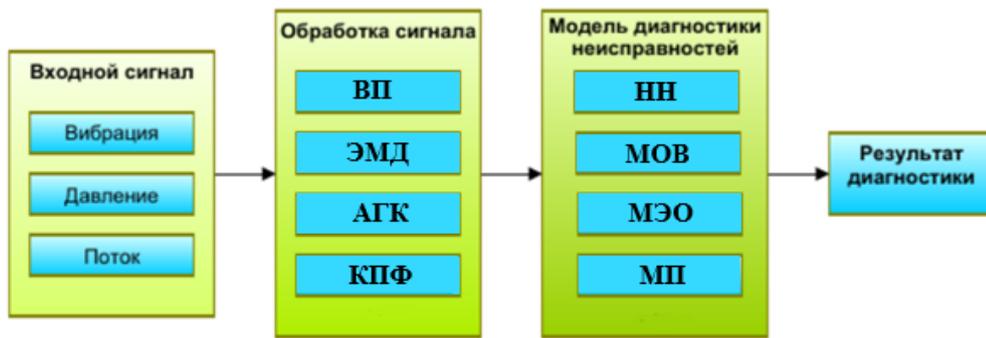


Рисунок 2.2 – Блок-схема диагностирования неисправностей гидравлического насоса

Вывод по второй главе

1. Проведенный анализ современных методов вибродиагностирования гидравлических систем показал, что наиболее перспективными являются методы, основанные на обработке сигналов в сочетании с алгоритмами машинного обучения. При этом комбинированные подходы, совмещающие несколько источников данных и методов анализа, позволяют повысить точность и эффективность диагностирования в условиях нестационарных и зашумленных сигналов.

2. Основными ограничениями существующих методов являются: необходимость экспертного подбора параметров обработки, основанного на опыте человека или обученности алгоритмов; снижение достоверности анализа при работе с нестационарными сигналами; недостаточная чувствительность к начальным стадиям развития дефектов в условиях значительных внешних помех.

3. Для устранения выявленных ограничений при диагностировании гидравлических насосов необходима разработка комбинированного метода, который обеспечивает автоматизированное извлечение и отбор информативных признаков из вибрационных сигналов с последующим применением методов искусственного интеллекта для построения модели классификации технических состояний.

ГЛАВА 3. РАЗРАБОТКА КОМБИНИРОВАННОГО МЕТОДА ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ НАСОСОВ СЕЛЬСКОХОЗЯЙСТВЕННОЙ ТЕХНИКИ

3.1 Разработка алгоритма комбинированного метода вибродиагностирования гидравлических насосов сельскохозяйственной техники

Основными достижениями в анализе вибрации в последние годы являются развитие методов обработки сигналов диагностирования вибрации зубчатых передач [112, 113] и неисправностей подшипников [114, 115]. Анализ сигналов вибрации часто основывался на быстром преобразовании Фурье (БПФ) [116, 117]. Этот подход имеет некоторые ограничения: 1) ошибки в сигнале вибрации делают БПФ неэффективным для описания нестационарности; 2) вторым ограничением и наиболее важным является разрешение по частоте, то есть способность различать спектральные отклики на две или многие гармоники; еще одно ограничение связано с разбиением данных на окна во время обработки БПФ. Чтобы преодолеть эти ограничения производительности, присущие подходу БПФ, за последние два десятилетия было предложено множество современных методов спектральной оценки [118-120]. Спектральная плотность мощности (СПМ) является одним из тех методов, о которых сообщается в нескольких исследовательских работах [121-122].

Методы, основанные на знаниях [123, 124], становятся подходящей стратегией автоматического обнаружения неисправностей (АОН). Нечеткая логика относится к методам, основанным на знаниях, для решения проблемы обнаружения ошибок. Несколько исследователей [125, 126] предложили подходы к обнаружению и диагностированию неисправностей, основанные на нечеткой системе. Нечеткая система – это подход, основанный на правилах, при котором набор правил обычно формируется на основе опыта эксперта или предварительных знаний о системе. Процесс обнаружения неисправностей

можно рассматривать как проблему классификации, и, следовательно, нечеткая система действует как классификатор для различения неисправностей в соответствии с ее правилами. Следовательно, успех процесса обнаружения ошибок зависит от адекватности нечетких правил. Как правило, нечеткие правила генерируются интуицией и экспертными знаниями. Однако для сложных систем с большим количеством избыточных признаков вывод нечетких правил утомителен и неточен. Исследователи постоянно пытались найти эффективные и действенные методы для создания этих нечетких правил. Для решения проблемы были предложены деревья решений [127].

Предметом данных исследования является предложение новой интеллектуальной системы вибродиагностирования гидравлических насосов. Предлагаемый подход состоит из трех этапов. Во-первых, рассчитывается СПМ сигналов вибрации из-за его лучшей производительности при иллюстрации неисправностей, а не методом БПФ. Во-вторых, дерево решений выполняется как инструмент выбора признаков для выделения признаков и определения структуры классификатора на следующем этапе. В-третьих, классификатор нечеткой логики используется для диагностирования неисправностей гидравлического насоса.

Схема работы предлагаемого комбинированного состоит из пяти этапов, как показано на рисунке 3.1: сбор данных, создание спектральной плотности мощности сигнала, извлечение признаков, выбор признаков и извлечение модели классификации, а также диагностика неисправностей, которые подробно объясняются в следующих разделах. Обобщенная роль каждой процедуры описана следующим образом:

Сбор данных: эта процедура используется для получения сигналов вибрации. Кроме того, выполняется обработка данных.

Создание СПМ: спектральная плотность мощности сигналов вибрации рассчитывается по формуле.

Извлечение признаков: наиболее значимые признаки рассчитываются с использованием статистических параметров.



Рисунок 3.1 – Предлагаемая схема вибродиагностирования комбинированным методом гидравлических насосов сельскохозяйственной техники

Выбор признаков и извлечение модели классификации: алгоритм J48 используется в качестве дерева решений для выбора существенных признаков из всего набора признаков. В этом разделе данные, полученные в результате

процедуры извлечения признаков, разделены на два набора данных: данные обучения и данные тестирования. Данные обучения используются для построения модели, в то время как данные тестирования предназначены для проверки модели.

Диагностирование неисправностей: для диагностирования неисправностей используется система нечеткого логического вывода.

Экспериментальные исследования выполнены в учебно-научно-производственном центре (УНПЦ) садоводства и овощеводства имени В.И. Эдельштейна ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева. Для проверки (тестирования) разработанного метода использовался гидронасос НШ-32А, на тракторе МТЗ-82. В этом насосе используются две вращающиеся шестерни, которые не входят в зацепление на стороне всасывания насоса, создавая пустоты, которые позволяют атмосферному давлению нагнетать жидкость в насос. Промежутки между зубьями шестерни переносят жидкость по внешнему периметру корпуса к стороне нагнетания, а затем шестерни снова входят в зацепление в центре, чтобы выпустить жидкость. Шестерни поддерживаются подшипниками скольжения с обеих сторон, что обеспечивает высокое давление нагнетания. В качестве гидравлической жидкости использовали масло И-20А. Для получения вибросигнала использовался пьезоэлектрический акселерометр (модель Metrix SA6200А), установленный на корпусе насоса (рис. 3.2). Характеристики датчика представлены в таблице 3.1.

Акселерометр по проводам подключен к блоку формирования сигнала (анализатору X-Viber FFT), где сигнал проходит через усилитель заряда и аналого-цифровой преобразователь (АЦП). Сигнал вибрации в цифровом виде подается на компьютер через порт USB. Программное обеспечение SpectraPro-4, прилагаемое к блоку формирования сигналов, используется для записи сигналов непосредственно в память компьютера.



Рисунок 3.2 – Расположение датчика на корпусе насоса

Таблица 3.1 – Характеристики акселерометра

Параметр, размерность	Значение
Диапазон измеряемых частот, Гц	0,5...10000
Температурный диапазон, °С	-54...+121
Резонансная частота, кГц	13
Материал корпуса	Нержавеющая сталь
Материал чувствительного элемента	Кварц
Масса, г	91

Затем сигнал считывается из памяти и обрабатывается для извлечения БПФ спектра вибрации. Максимальная частота сигнала составляла 1 кГц при 4010 дискретных данных, что давало измеренное время 2,1 секунды. Первоначально данные были получены от исправно работающего насоса. Затем были измерены данные насоса с неисправными компонентами, которые описаны в таблице 3.2. В качестве условий испытаний рассматривались три

скорости вращения вала насоса (1000, 1500 и 2000 об/мин). На рисунке 3.3 показаны исследуемые детали гидравлического насоса.

Создание СПМ

Функция спектральной плотности мощности (СПМ) показывает силу вариаций (энергии) в зависимости от частоты. Другими словами, она показывает, на каких частотах вариации сильные, а на каких слабые [128].

Таблица 3.2 – Неисправности насоса, принимаемые в учет

Номер	Тип неисправности	Метка классификации
1	Рабочий насос	НОРМ
2	Опорный подшипник с внутренним торцевым износом	ИПТ
3	Шестерня с износом торца зуба	ИТЗ
4	Сочетание неисправностей номер 2 и 3	КОМБ

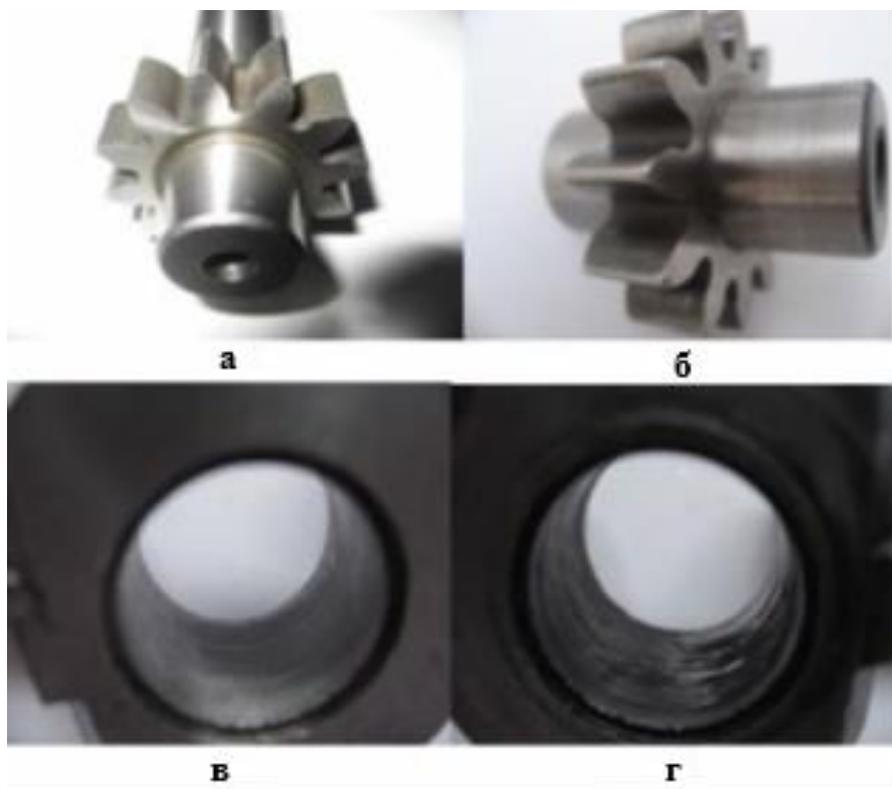


Рисунок 3.3 – а. Исправная шестерня. б. Шестерня с износом торца зуба (ИТЗ). в. Рабочий опорный подшипник. г. Опорный подшипник с внутренним износом (ИПТ)

Комплексный спектр вибрации $x(t)$ во временном интервале (t_1, t_2) для любой частоты f в двусторонней частотной области $(-F, +F)$ можно представить в виде (3.1).

$$X(f) = \int_{f_1}^{f_2} x(t) e^{-2\pi i f t} dt. \quad (3.1)$$

Если $x(t)$ выражается в единицах $(\text{м}/\text{с}^2)$, $X(f)$ выражается в единицах $(\text{м}/\text{с}^2)/\text{Гц}$. Из комплексного спектра можно вычислить одностороннюю спектральную плотность мощности в $(\text{м}/\text{с}^2)^2/\text{Гц}$ по формуле (3.2).

$$\text{СПМ}(f) = \frac{2|X(f)|^2}{(t_2 - t_1)}, \quad (3.2)$$

где коэффициент 2 обусловлен суммированием вкладов положительных и отрицательных частот.

СПМ распределяет общую мощность вибрации. Чтобы увидеть это, необходимо проинтегрировать его по всей его односторонней частотной области $(0, F)$:

$$\int_0^f \text{СПМ}(f) df = \frac{\int_{f_1}^{f_2} |x(t)|^2 dt}{(t_2 - t_1)}. \quad (3.3)$$

Результатом является именно средняя мощность вибрации во временном диапазоне (t_1, t_2) .

Если используется БПФ сигнала вибрации, СПМ можно рассчитать непосредственно в частотной области по следующей формуле [129, 130]:

$$\text{СПМ} = \frac{G_{rms}^2}{f}, \quad (3.4)$$

где G_{rms} – среднеквадратичное ускорение на определенной частоте f .

Извлечение признаков

Измеренные значения СПМ сигнала были рассчитаны для получения наиболее значимых признаков путем выделения признаков. Точность выделения признаков имеет большое значение, поскольку она напрямую влияет на окончательные результаты диагностирования. В этом исследовании использовалось извлечение признаков с использованием описательной статистики из значений СПМ сигналов вибрации. В исследовательских работах сообщалось об использовании этого метода [131-133]. Параметры:

Среднее, Стандартное отклонение, Медиана, Выборочная дисперсия, Эксцесс, Асимметрия, Минимум, Максимум и Сумма. Эти статистические параметры объясняются следующим образом.

Среднее: это среднее значение всех значений сигнальных точек в данном сигнале.

Стандартное отклонение: это мера эффективной энергии или мощности вибрационного сигнала. Для расчета стандартного отклонения использовалась следующая формула.

$$\text{Стандартное отклонение} = \sqrt{\frac{n\sum x^2 - (\sum x)^2}{n(n-1)}}, \quad (3.5)$$

где n – размер выборки.

Медиана: это значение, отделяющее верхнюю половину значений сигнальных точек от нижней половины.

Асимметрия: Асимметрия характеризует степень асимметрии распределения относительно его среднего значения. Приведенное ниже выражение использовалось для расчета асимметрии:

$$\text{Асимметрия} = \frac{n}{(n-1)(n-2)} \sum \left(\frac{x_i - \bar{x}}{s} \right)^3, \quad (3.6)$$

где s – стандартное отклонение выборки.

Эксцесс: Эксцесс указывает на плавность или резкость сигнала. Для вычисления эксцесса использовалась следующая формула:

$$\text{Эксцесс} = \left\{ \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum \left(\frac{x_i - \bar{x}}{s} \right)^4 \right\} - \frac{3(n-1)^2}{(n-2)(n-3)}. \quad (3.7)$$

Выборочная дисперсия: это дисперсия сигнальных точек, и для расчета выборочной дисперсии использовалась следующая формула:

$$\text{Выборочная дисперсия} = \frac{n\sum x^2 - (\sum x)^2}{n(n-1)}. \quad (3.8)$$

Минимальное значение: относится к минимальному значению сигнальной точки в данном сигнале.

Максимальное значение: относится к максимальному значению сигнальной точки в данном сигнале.

Сумма: это сумма всех значений точек сигнала в данном сигнале.

Выбор признаков и извлечение модели классификации

Подход “разделяй и властвуй” к проблеме обучения на множестве независимых примеров естественным образом приводит к стилю представления, называемому деревом решений. Дерево решений – это основанная на дереве методология представления знаний, используемая для представления правил классификации. Стандартное дерево, созданное с помощью c5.0 (или, возможно, ID3 или c4.5), состоит из нескольких ветвей, одного корня, нескольких узлов и нескольких листьев. Одна ветвь представляет собой цепочку узлов от корня до листа, и каждый узел включает в себя один атрибут. Вхождение атрибута в дерево предоставляет информацию о важности связанного атрибута. В дереве решений верхний узел является лучшим узлом для классификации. Другие признаки в узлах дерева решений отображаются в порядке убывания важности. Здесь следует подчеркнуть, что в дереве решений появляются только те признаки, которые способствуют классификации, а другие нет. Признаки с меньшей способностью различать можно сознательно отбросить, выбрав порог. Эта концепция используется для выбора информативных признаков.

В этом исследовании алгоритм J48 (реализация алгоритма c4.5 WEKA) использовался для построения деревьев решений [134]. Входными данными для алгоритма был набор статистических характеристик, извлеченных из значений СПМ вибрационных сигнатур. Подробные описания этих наборов данных приведены в таблице 3.3. На основе выходных данных алгоритма J48 выбираются различные статистические параметры для различных состояний насоса. Выбранные статистические характеристики используются в качестве признаков принадлежности, а значения, появляющиеся между различными узлами в дереве решений, используются для генерации нечетких правил при классификации различных состояний исследуемого насоса.

Таблица 3.3 – Описание наборов данных в каждом состоянии

Метка классификации	Количество обучающих выборок	Количество испытываемых образцов
НОРМ	13	7
ИПТ	13	7
ИТЗ	13	7
КОМБ	13	7
Всего образцов	52	28

Диагностирование неисправностей с использованием системы нечетких выводов. Нечеткая логика использует знания экспертов, что возможно благодаря их преобразованию в лингвистические термины. Нечеткая логика – это система, основанная на правилах, которая успешно сочетает в себе теорию нечетких множеств с возможностями экспертного вывода. В качестве правил используются лингвистические термины, которые моделируются через функции принадлежности, представляющие собой моделирование понимания экспертом. Функции принадлежности дают масштабированное значение определенных числовых значений, которые определяются лингвистическими метками. Определены такие правила, как ЕСЛИ (условие), ТО (результат). Условия и результаты – это лингвистические термины, которые представляют входные и выходные переменные соответственно. База правил классификатора нечеткой логики состоит из множества правил. База правил используется для получения определенного выходного значения в соответствии с входным значением.

Общий механизм нечеткого логического вывода показан на рисунке 3.4. В механизме нечеткого логического вывода “ x ” – это входное значение, $\mu(x)$ – нечеткое значение, $\mu(u)$ – результат операции вывода, а “ u ” является выходным значением. Блок фаззификатора преобразует четкие данные на входе механизма логического вывода в формат лингвистических переменных.

База знаний представляет собой: базу данных и базу правил. В то время как база данных включает определение каждой системной переменной с использованием нечеткого множества, база правил охватывает правила проверки, необходимые для получения реальных результатов. Блок вывода – это блок, который выполняет нечеткий вывод по нечетким правилам. Этот блок выполняет операцию, напоминающую способ мышления человека. Наконец, блок дефаззификации преобразует нечеткие значения, полученные на выходе блока логического вывода, в числовые значения. Эта операция называется дефаззификацией [135].



Рисунок 3.4. – Механизм нечеткого вывода

После определения функций принадлежности и создания правил “ЕСЛИ–ТО” с помощью алгоритма J48 следующим шагом является построение механизма нечеткого вывода. Набор нечетких инструментов, доступный в MATLAB [136], использовался для создания механизма нечеткого вывода. Каждое правило было взято за основу, и с использованием функций принадлежности и нечетких операторов были введены правила.

3.2 Анализ результатов исследований

СПМ-частотные диаграммы

На рисунке 3.5 показаны образцы диаграммы СПМ-частоты сигналов вибрации, полученных для различных экспериментальных условий насоса. Согласно этому рисунку видно, что при каждой рабочей скорости насоса максимальное значение СПМ увеличивается за счет увеличения серьезности неисправности насоса.

Деревья решений.

Результаты алгоритма J48 показаны на рисунках 3.6–3.8. Деревья решений показывают взаимосвязь между признаками и состоянием насоса. Прослеживание ветки от корневого узла приводит к состоянию насоса, а расшифровка имеющейся в ветке информации в виде оператора “ЕСЛИ-ТО” дает правила классификации с использованием нечеткой для различных состояний насоса. Таким образом, установлена полезность дерева решений для формирования правил нечеткой классификации. Верхний узел дерева решений является лучшим узлом для классификации. Остальные признаки появляются в узлах дерева решений в порядке убывания важности. Здесь следует подчеркнуть, что в дереве решений появляются только те признаки, которые способствуют классификации, а другие нет. Уровень вклада неодинаков, и все статистические характеристики не одинаково важны.

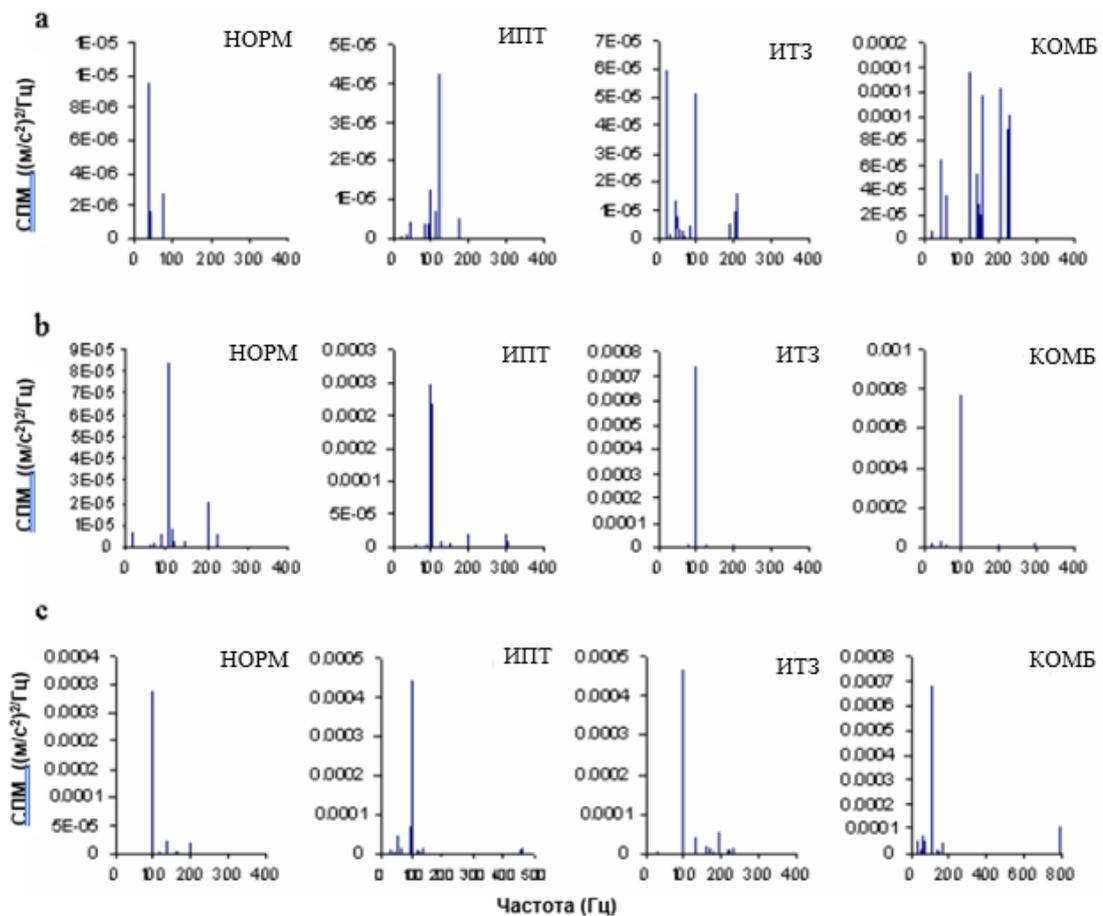


Рисунок 3.5 – СПМ-частотные диаграммы насоса в а. 1000 об/мин, б. 1500 об/мин и с. 2000 об/мин

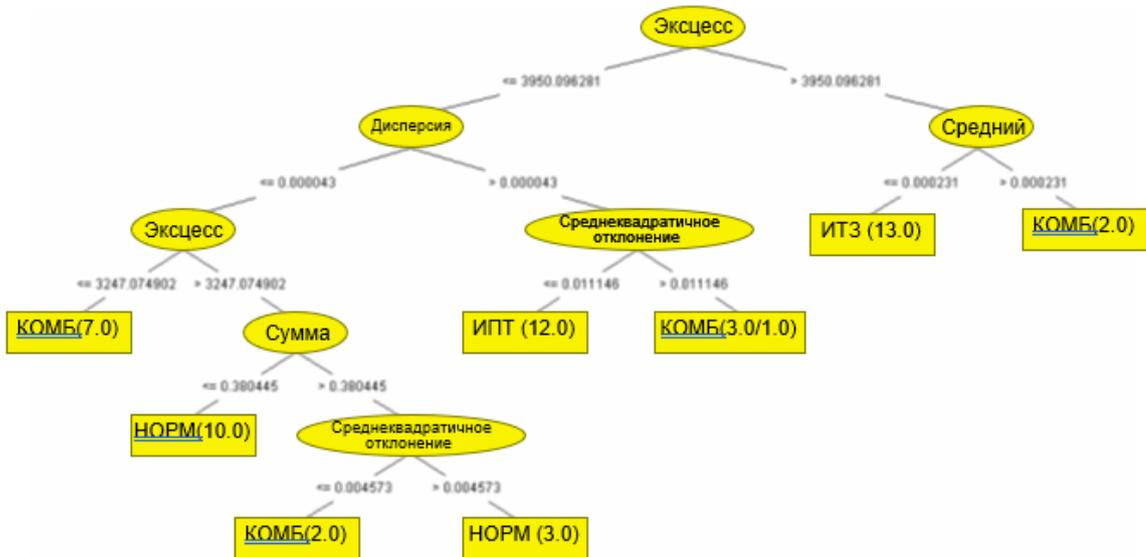


Рисунок 3.6 – Дерево решений по алгоритму J48 для условия 1000 об/мин

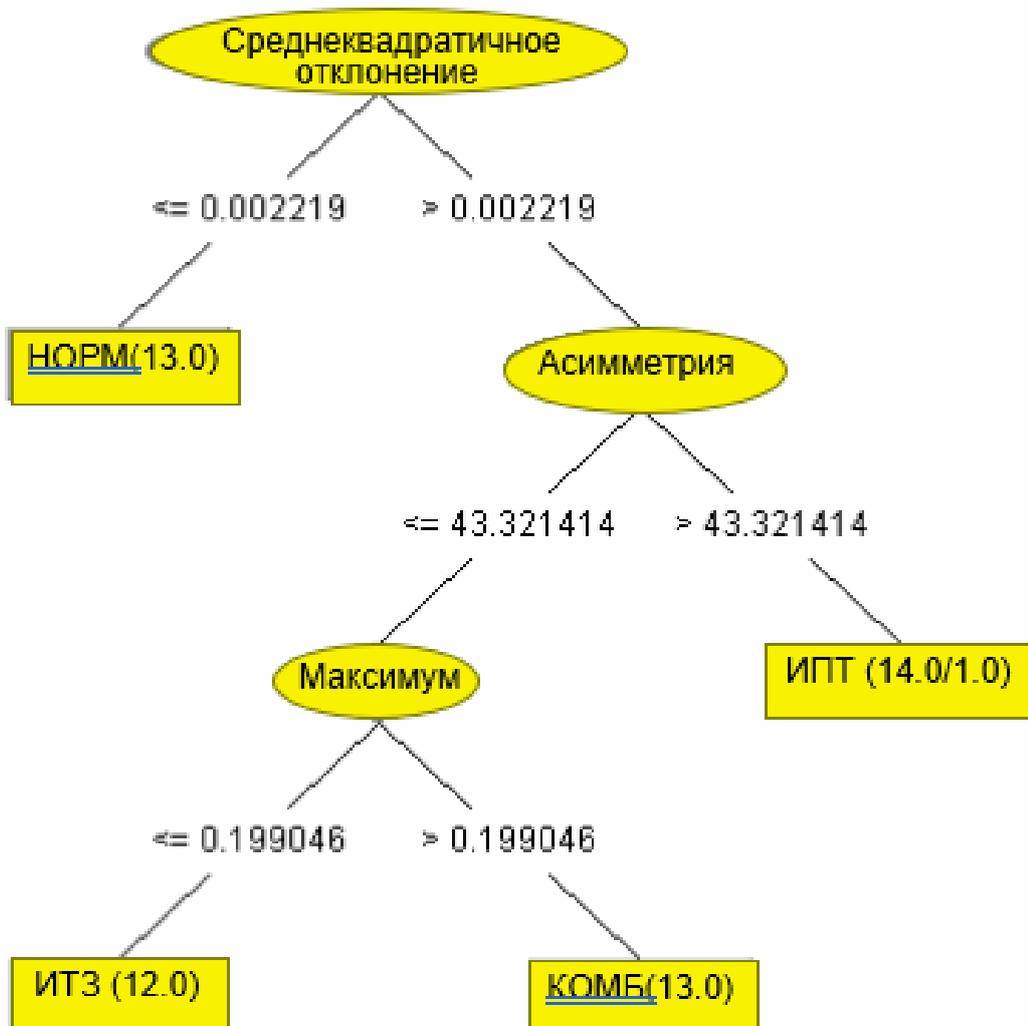


Рисунок 3.7 – Дерево решений по алгоритму J48 для условия 1500 об/мин

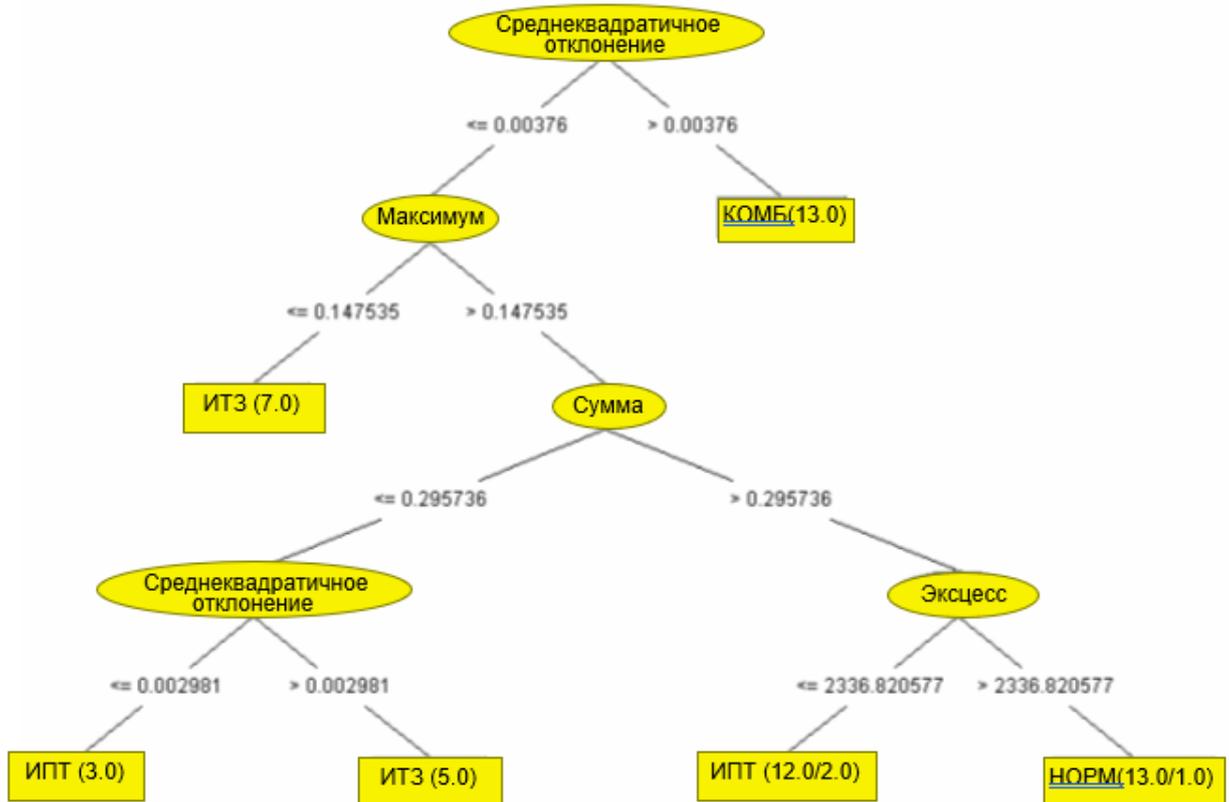


Рисунок 3.8 – Дерево решений по алгоритму J48 для условия 2000 об/мин

Уровень вклада отдельных признаков задается статистической мерой в скобках в дереве решений. Первое число в скобках указывает количество точек данных, которые можно классифицировать с помощью этого набора признаков. Второе число указывает количество выборок против этого действия. Если первое число очень мало по сравнению с общим количеством выборок, то соответствующие признаки можно рассматривать как выбросы и, следовательно, игнорировать. Алгоритм идентифицирует признаки для целей классификации из заданного набора обучающих данных и, таким образом, уменьшает знание предметной области, необходимое для выбора диагностических признаков для задачи классификации шаблонов.

Функции принадлежности

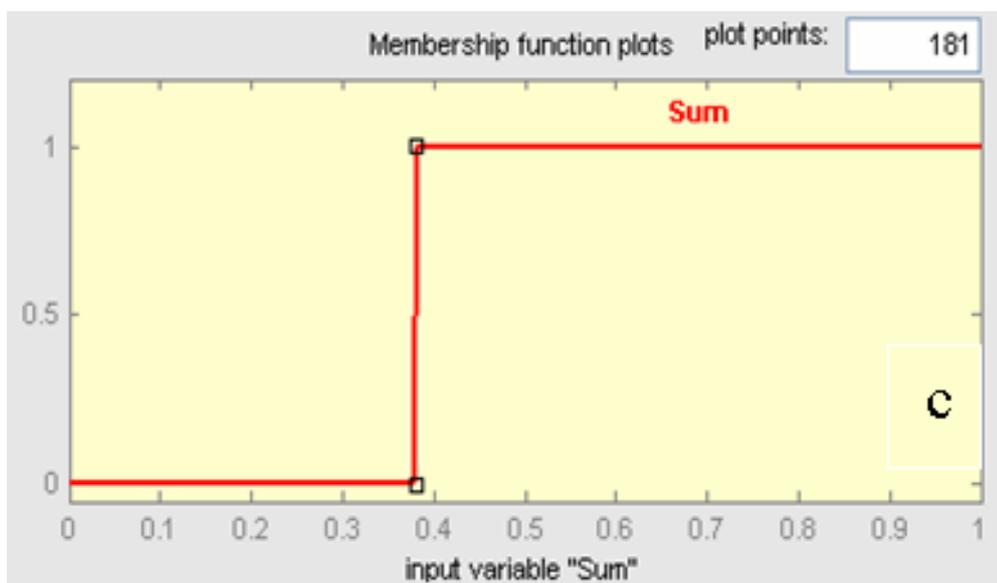
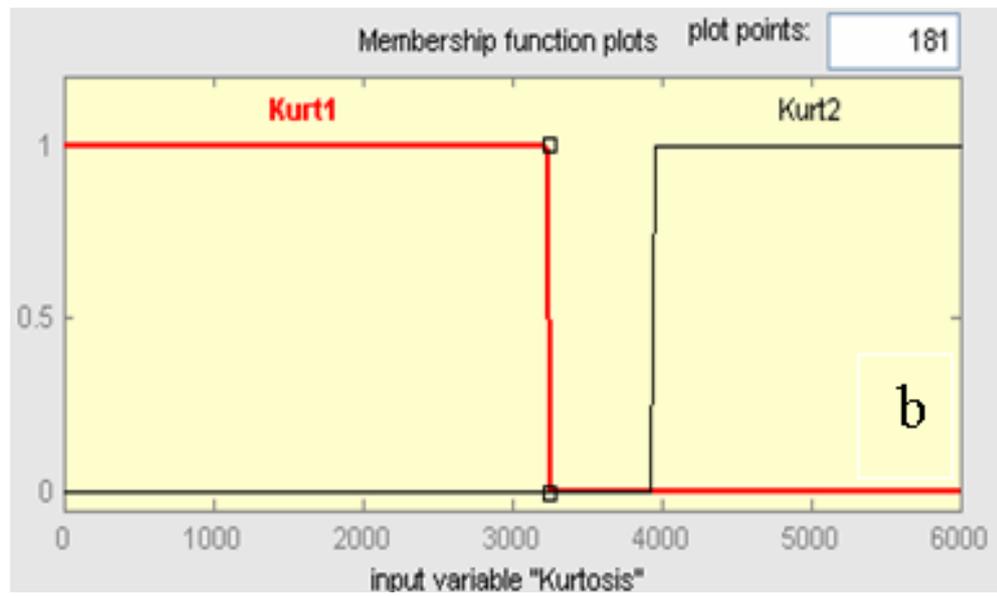
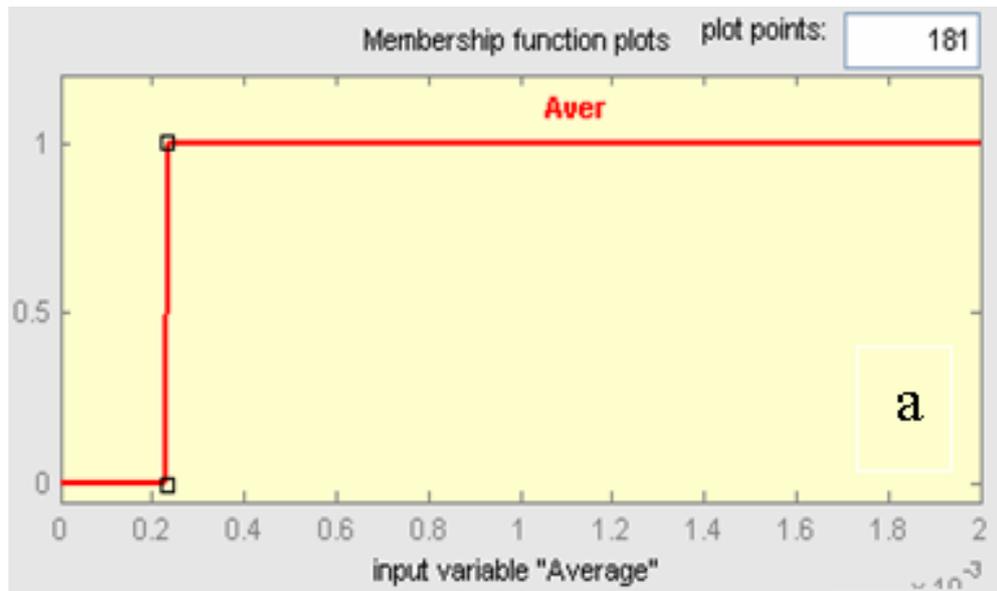
Функция принадлежности (ФП) представляет собой кривую, которая определяет, как каждая точка во входном пространстве сопоставляется со значением принадлежности (или степенью принадлежности) от 0 до 1. Наблюдение за значениями признака, на основе которых ветви решения

создаются деревья для разных состояний насоса, определяются ФП для соответствующих характеристик.

Состояние 1000 об/мин

Из рисунка 3.6 видно, что среднее значение, эксцесс, дисперсия, стандартное отклонение и сумма играют решающую роль в классификации различных неисправностей насоса для этого состояния. Этот вывод дерева решений используется для проектирования ФП для нечеткого классификатора, как показано на рисунке 3.9. В настоящем исследовании используется трапецевидный ФП. Выбор этой ФП в некоторой степени произволен. Однако при выборе ФП учитывались следующие моменты. Наблюдая за значениями признака, на основе которого создаются ветви дерева решений, определяются ФП для всех пяти признаков – для среднего, эксцесса, суммы, дисперсии и стандартного отклонения соответственно.

Из рисунка 3.6 видно, что 0,000231 является порогом для значения принадлежности к среднему. До этого порогового значения ФП формирует значение «0», а затем линейно увеличивается (допущение). Трапецевидный ФП подходит для этого явления, и поэтому он был выбран для сопоставления каждой точки входного пространства со значением принадлежности (рисунок 3.9 а). Для просмотра пороговые значения задаются деревом решений, а наклон определяется пользователем с помощью эвристики. Пороговое значение (0,000231) определяется на основе репрезентативного набора обучающих данных. Если среднее значение меньше или равно 0,000231, ФП, определенный по шкале от 0 до 1, дает значение 0, что означает, что это не среднее значение. Если пороговое значение больше 0,000231, ФП генерирует значение 1. Аналогичным образом, ФП для других признаков спроектированы соответствующим образом и показаны на рисунках 3.9 b-e. Существует четыре возможных результата нечеткого классификатора, а именно: НОРМ, ИПТ, ИТЗ и КОМБ. Следовательно, четыре ФП определены с одинаковым диапазоном и показаны на рисунке 3.10.



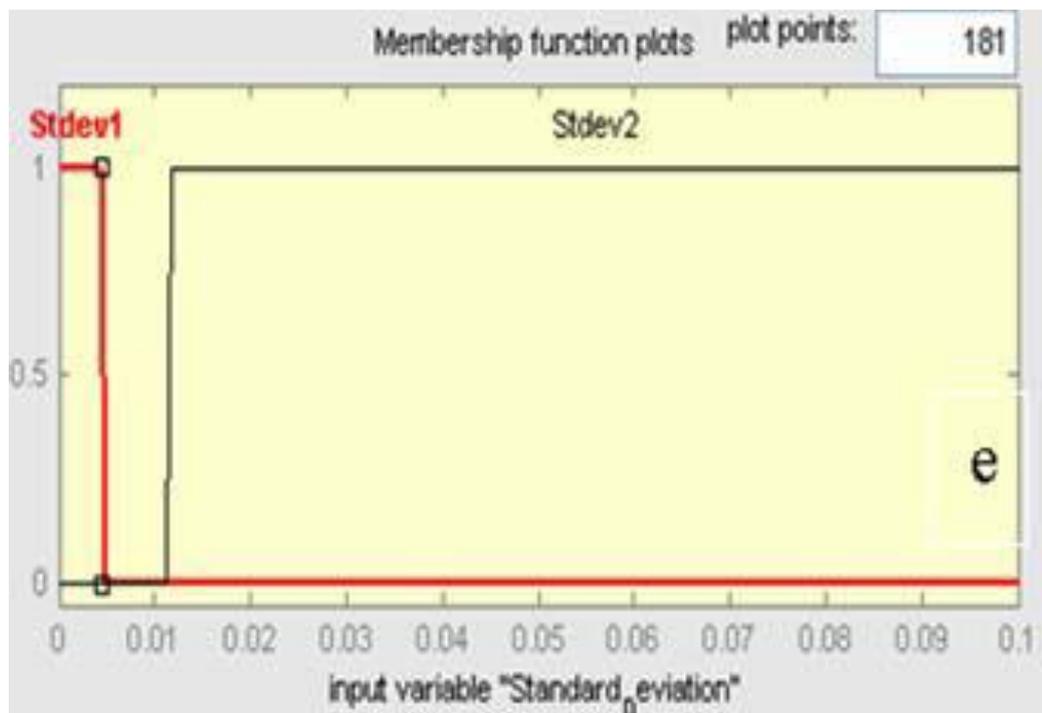
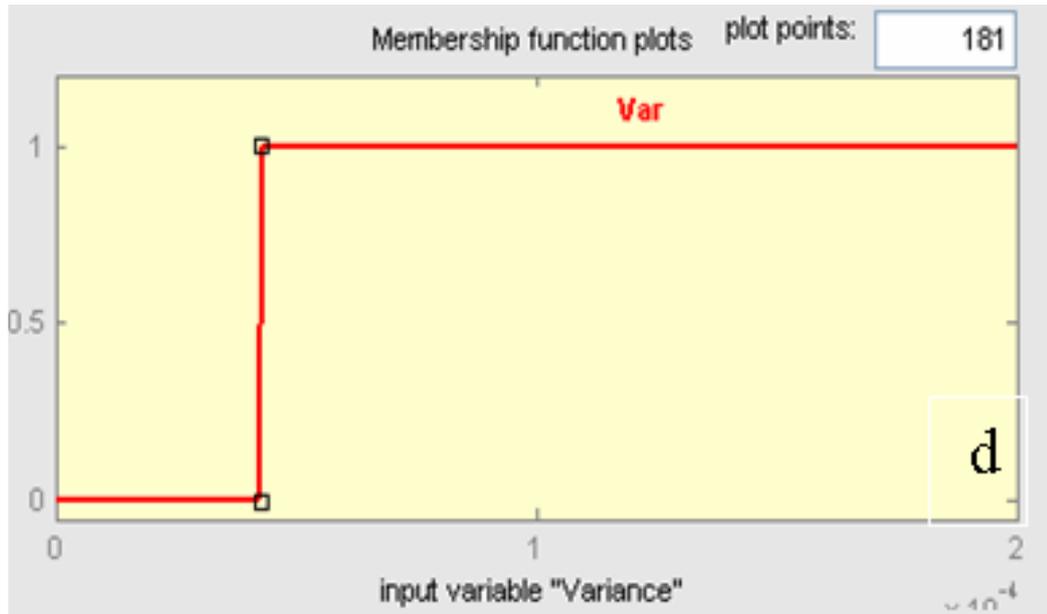


Рисунок 3.9 – ФП для: а. “Средний”, б. “Экссес”, д. “Сумма”,
д. «Дисперсия», е. "Стандартное отклонение"

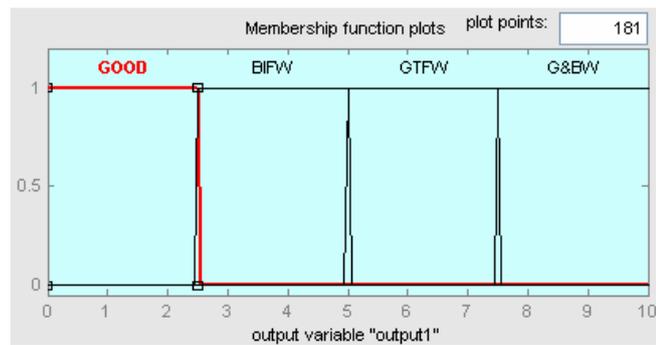


Рисунок 3.10 – ФП для выхода (“Выход1”)

2) Состояние 1500 об/мин. См. рисунок 3.11.

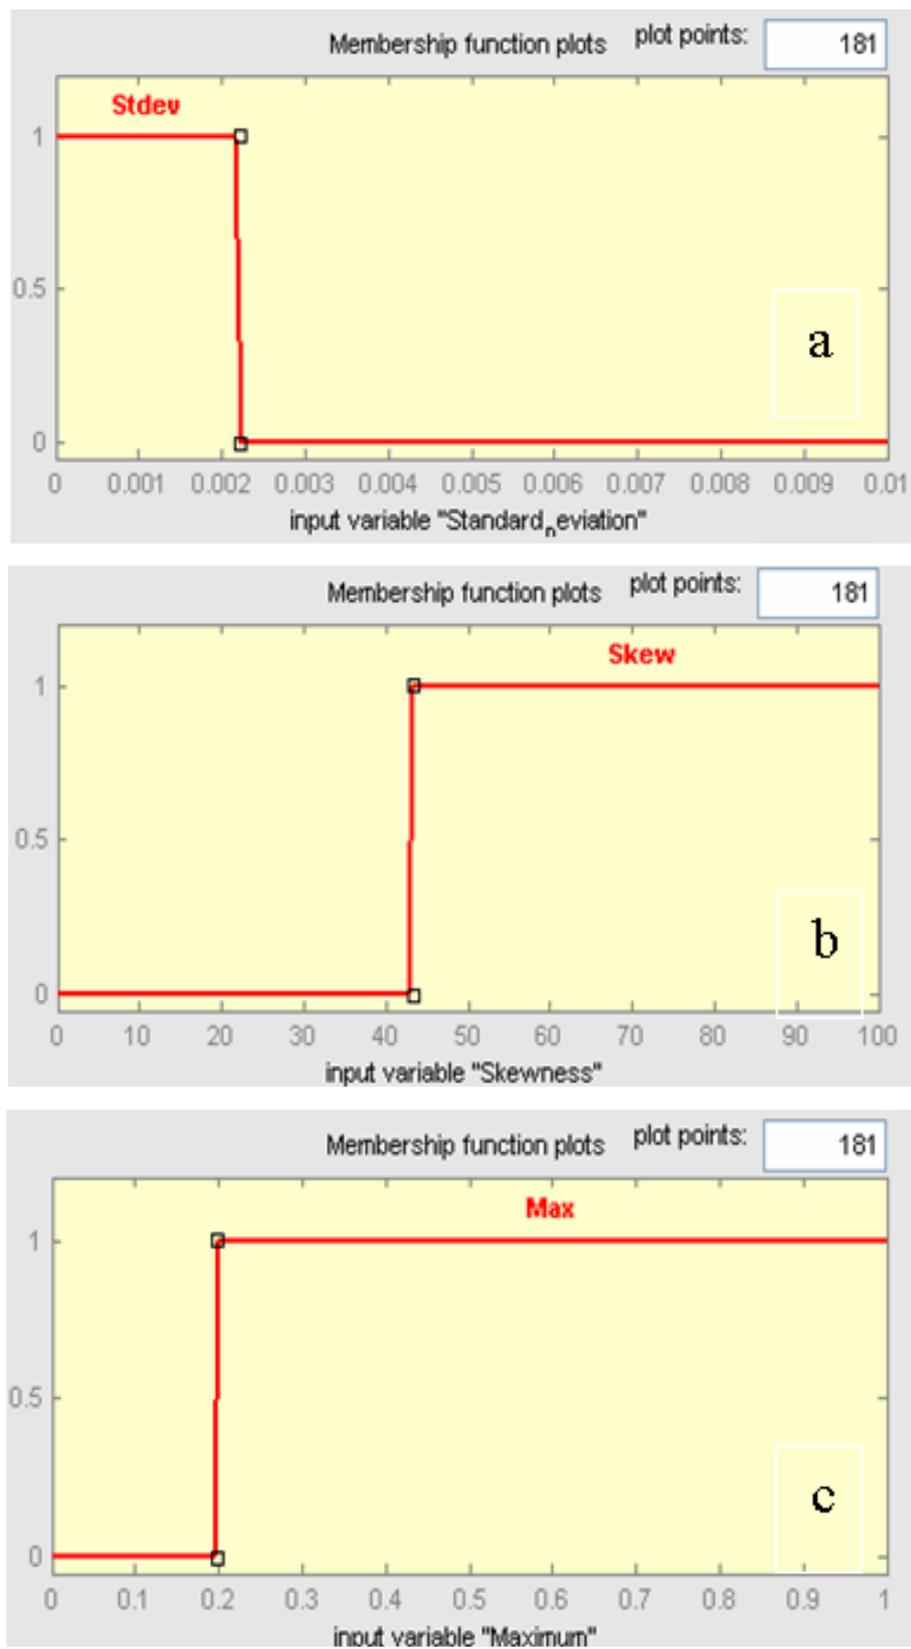


Рисунок 3.11 – ФП для а. "Стандартное отклонение", б. «Асимметрия»
с. "Максимум".

3) Состояние 2000 об/мин. См. рисунок 3.12

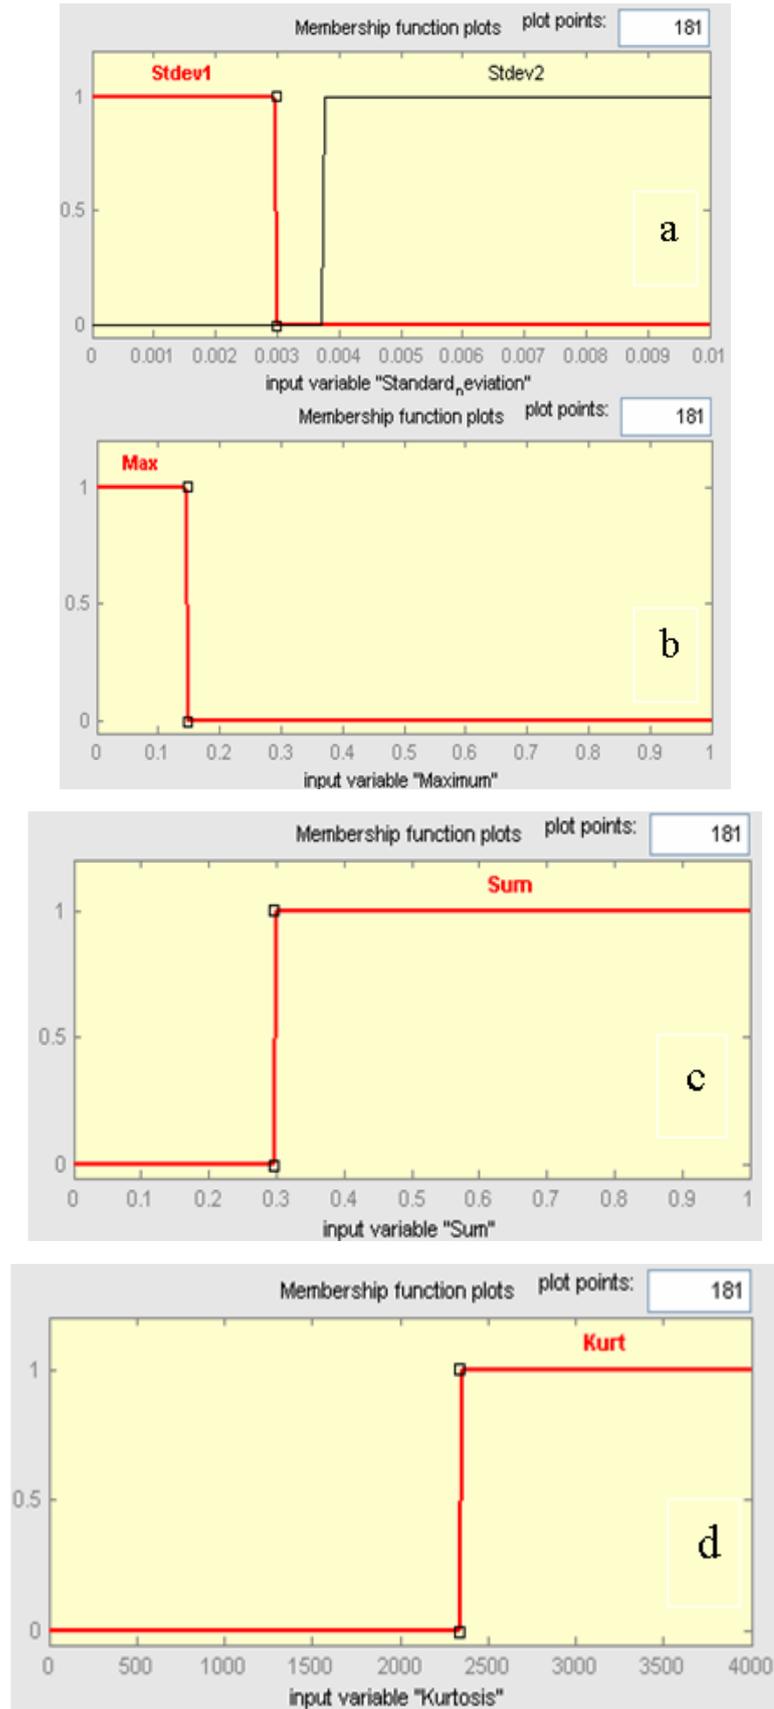


Рисунок 3.12 – ФП для а. “Стандартное отклонение”, б. “Максимум”, с. “Сумма”, d. “Эксцесс”.

Нечеткие правила

Используя рисунки 3.6-3.8, нечеткие правила были разработаны с операторами “ЕСЛИ-ТО”. Все правила оцениваются параллельно, и порядок правил не имеет значения.

1) Правила для на 1000 об/мин.

1. Если (Эксцесс) – это Kurt2) и (Среднее значение – это Aver), то (Output1 (Выход1) – это КОМБ)

2. Если (Эксцесс – это Kurt2) и (Среднее значение – это не Aver), то (Output1 (Выход1) – это ИТЗ)

3. Если (Эксцесс – это не Kurt2) и (Дисперсия) – это Var) и (Стандартное отклонение – это Stdev2), то (Output1 – это КОМБ)

4. Если (Эксцесс – это не Kurt2) и (Дисперсия – это Var) и (Стандартное отклонение) – это не Stdev2), то (Выход1 – это ИПТ)

5. Если (Дисперсия – это не Var) и (Эксцесс – это не Kurt1, то (Output1 – это КОМБ)

6. Если (Дисперсия не Var) и (Эксцесс – это не Kurt1) и (Сумма) равна Sum) и Стандартное отклонение равно Stdev1), то (Output1 равно КОМБ)

7. Если (Дисперсия не Var) и (Эксцесс не Kurt1) и (Сумма есть Sum) и (Стандартное отклонение не Stdev1), то (Output1 НОРМ)

8. Если (Дисперсия не Var) и (Эксцесс – это не Kurt1) и (Сумма не является Sum), тогда (Output1 НОРМ)

Рисунок 3.13 иллюстрирует применение разработанных правил. Здесь каждая строка соответствует каждому правилу, как описано в этом разделе. Первые пять блоков в строках представляют ФП эксцесса, среднего значения, дисперсии, стандартного отклонения и суммы соответственно. Шестой блок соответствует ФП для вывода, как показано на рисунке 3.10. С помощью выборочных входных данных для эксцесса, среднего значения, дисперсии, стандартного отклонения и суммы правила проверяются следующим образом для выборочного ввода эксцесса как 3000, среднее значение равно 0,001, дисперсия равна 0,0001, стандартное отклонение равно 0,05, а сумма равна 0,5,

что полностью удовлетворяет третьему правилу и соответствует выходному условию КОМБ, которое показано в блоке вывода третьей строки в средстве просмотра правил, показанном на рисунке 3.13.

2) *Правила для 1500 об/мин.*

1. Если (Стандартное отклонение равно Stdev), то (Output1 является НОРМ).

2. Если (Стандартное отклонение не является Stdev) и (асимметрия является асимметрией), то (Output1 является ИПТ).

3. Если (Стандартное отклонение не является стандартным отклонением) и (Асимметрия не является Skew) и (Максимум равен Max), то (Output1 – КОМБ)

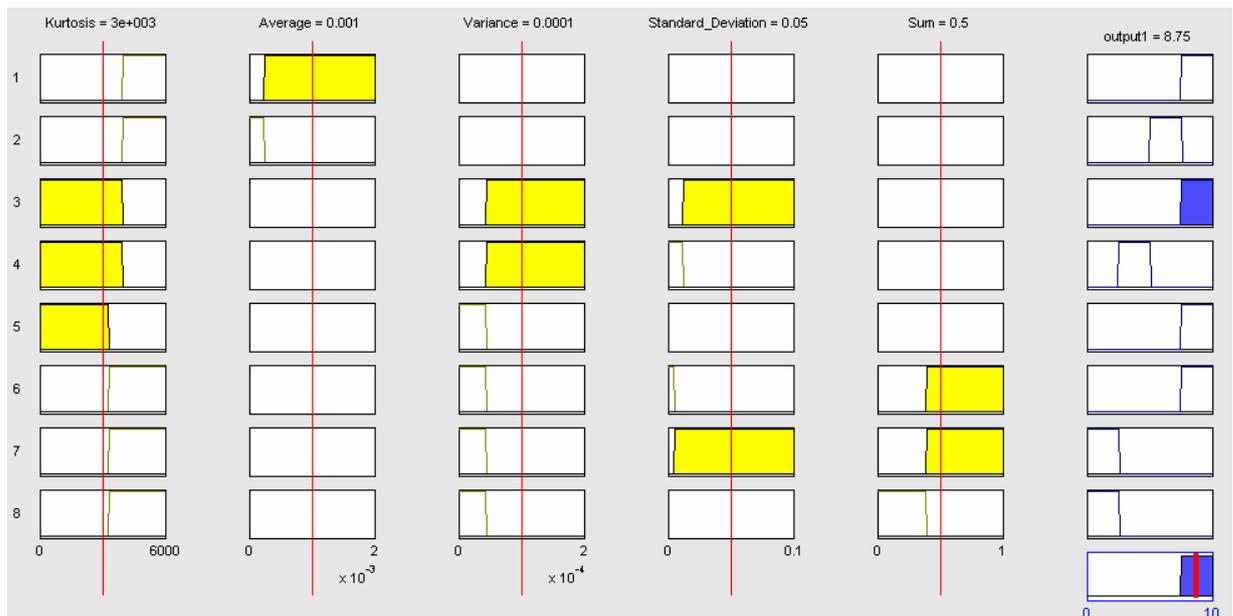


Рисунок 3.13 – Средство просмотра правил для одного из тестовых данных условия 1000 об/мин

4. Если (Стандартное отклонение не является Stdev) и (Асимметрия не является Skew) и (Максимум не является Max), то (Output1 представляет собой ИТЗ)

На рисунке 3.14 показано средство просмотра правил для следующих тестовых данных. Если стандартное отклонение = 0,005, асимметрия = 50 и максимум = 0,5, то выход равен 3,75, т. е. условие ИПТ.

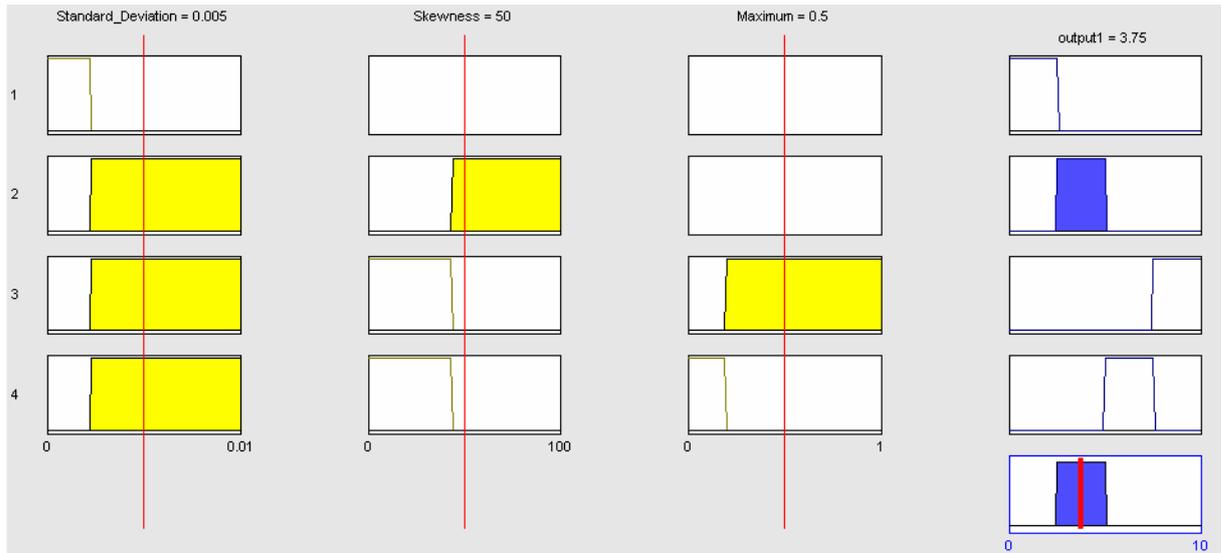


Рисунок 3.14 – Средство просмотра правил для одного из тестовых данных условия 1500 об/мин

3) Правила для 2000 об/мин.

1. Если (Стандартное отклонение равно Stdev2), то (Output1 равно КОМБ)
2. Если (Стандартное отклонение не равно Stdev2) и (Максимум равен Max), то (Output1 равно ИТЗ)
3. Если (Стандартное отклонение не равно Stdev2) и (Максимум не равен Max) и (Sum равно Sum) и (Эксцесс равно Kurt), то (Output1 равно НОРМ)
4. Если (Стандартное отклонение не равно Stdev2) и (Максимум не равен Max) и (Sum равно Sum) и (Эксцесс не Kurt), то (Output1 равно ИПТ)
5. Если (Максимум не равен Max) и (Максимум не равен Max) и (Стандартное отклонение равно Stdev1), то (Output1 равно ИПТ)
6. Если (Максимум не равен Max) и (Сумма не является Sum) и (Стандартное отклонение не равно Stdev1), то (Output1 равно ИТЗ)

На рисунке 3.15 показано средство просмотра правил для следующих тестовых данных. Если стандартное отклонение = 0,005, максимум = 0,5, сумма = 0,5 и эксцесс = 2000, тогда выход равен 8,8, т. е. условие КОМБ. Это полностью удовлетворяет первому правилу.

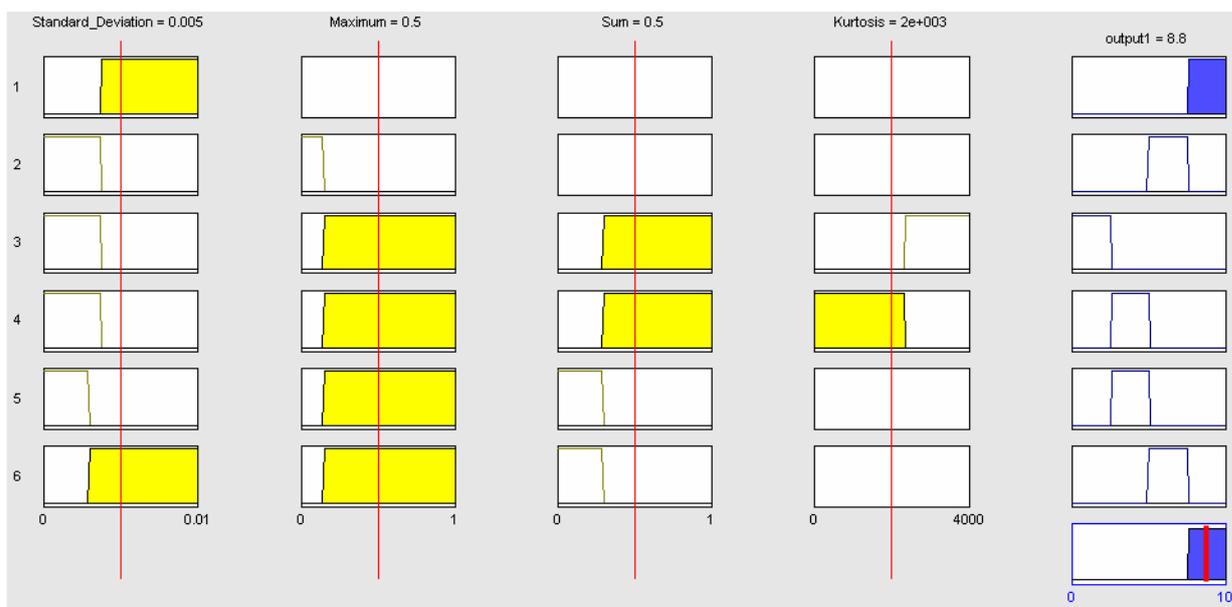


Рисунок 3.15 – Средство просмотра правил для одного из тестовых данных условия 2000 об/мин

Точность системы

Результаты классификации, рассчитанные с использованием 10-кратной перекрестной проверки, демонстрируют высокую эффективность предложенного метода СПМ-J48-СНВ. Матрицы неточностей для каждого режима работы приведены в таблицах 3.4–3.6. На их основе были рассчитаны ключевые статистические показатели, представленные в таблицах 3.6–3.8.

Таблица 3.4 – Матрица неточностей для условий 1000 об/мин

Условия	НОРМ	ИПТ	ИТЗ	КОМБ
НОРМ	6	1	0	0
ИПТ	0	6	1	1
ИТЗ	0	0	7	0
КОМБ	0	0	1	6

Таблица 3.5 – Матрица неточностей для условий 1500 об/мин

Условия	НОРМ	ИПТ	ИТЗ	КОМБ
НОРМ	6	1	0	0
ИПТ	1	6	0	0
ИТЗ	0	0	6	1
КОМБ	0	0	1	6

Таблица 3.6 – Матрица неточностей для условий 2000 об/мин

Условия	НОРМ	ИПТ	ИТЗ	КОМБ
НОРМ	6	0	1	0
ИПТ	0	7	0	0
ИТЗ	0	0	6	1
КОМБ	0	0	1	6

Работоспособность классификатора можно проверить путем вычисления статистических параметров, таких как чувствительность, специфичность и общая точность классификации, определяемых

- *Чувствительность*: количество действительно положительных решений/число действительно положительных случаев.
- *Специфичность*: количество истинно отрицательных решений/число действительно отрицательных случаев.
- *Общая точность классификации*: количество правильных решений/общее количество случаев.

Значения статистических параметров приведены в таблицах 3.7 – 3.9. Результаты показывают, что общая точность классификации для условий 1000, 1500 и 2000 об/мин составляет 92,9%, 96,4% и 92,9% соответственно. Здесь следует подчеркнуть, что, поскольку правила и ФП для системы нечеткого логического вывода были извлечены непосредственно из алгоритма J48, точность нечеткой системы почти равна точности дерева решений, построенного алгоритмом J48. Следовательно, это правильно, что эти суммы показывают точность системы нечеткого вывода и модели СПМ-J48-СНВ.

Таблица 3.7 – Значения статистических параметров для условий 1000 об/мин

Метка набора данных	Чувствительность (%)	Специфичность (%)	Общая классификация точности (%)
НОРМ	92,9	97,6	92,9
ИПТ	90,2	95,1	
ИТЗ	94,3	96,8	
КОМБ	91,5	96,3	

Таблица 3.8 – Значения статистических параметров для условий 1500 об/мин

Метка набора данных	Чувствительность (%)	Специфичность (%)	Общая классификация точности (%)
НОРМ	95,8	98,9	94,6
ИПТ	91,4	96,5	
ИТЗ	92,1	97,2	
КОМБ	96,3	99,1	

Таблица 3.9 – Значения статистических параметров для условий 2000 об/мин

Метка набора данных	Чувствительность (%)	Специфичность (%)	Общая классификация точности (%)
НОРМ	91,7	97,2	92,9
ИПТ	93,8	98,1	
ИТЗ	90,5	96,0	
КОМБ	92,0	97,5	

Таким образом, комбинированная спектральная плотность мощности, дерево классификации (алгоритм J48) и система нечеткого вывода (СНВ) разработаны для диагностики неисправностей гидравлического насоса. Реализация классификатора на основе СПМ-J48-СНВ требует трех последовательных шагов. Сначала по полученным спектрам рассчитывали значения СПМ вибрационного сигнала насоса. Во-вторых, алгоритм J48 используется для выбора соответствующих признаков в наборе данных, полученном из части извлечения признаков. Результатом алгоритма J48 является дерево решений, которое используется для создания четких правил “ЕСЛИ-ТО” и наборов ФП. В-третьих, структура классификатора определяется на основе полученных правил, которые были размыты, чтобы избежать неоднородности поверхности классификации. Затем результаты классификации и статистические показатели используются для оценки модели СПМ-J48-СНЛ. Общая точность классификации для условий 1000, 1500 и 2000 об/мин составила 92,9%, 94,6% и 92,9% соответственно. Результаты показывают, что предложенную модель СПМ-J48-СНЛ можно использовать для диагностирования неисправностей гидравлического насоса с внешним зацеплением.

Энергетический метод вибродиагностирования гидравлического насоса сельскохозяйственной техники. Как было показано выше, методы обработки сигналов широко используются для выделения характеристик неисправности вибрационных сигналов. Быстрое преобразование Фурье (БПФ), которое было доминирующим инструментом анализа для выделения признаков стационарных сигналов, может давать статистические средние характеристики по всей продолжительности данных [137, 138]. Однако оно не может определить все локальные характеристики сигнала во временной и частотной областях. БПФ имеет некоторые ограничения. Вследствие этих ограничений БПФ неэффективен для описания нестационарностей, вызванных ошибками в сигнале вибрации. Вторым ограничением и наиболее важным является разрешение по частоте, то есть способность различать спектральные

отклики на две или многие гармоники. Еще одно ограничение связано с разбиением данных на окна во время обработки БПФ. Чтобы преодолеть эти ограничения производительности, присущие методу БПФ, за последние два десятилетия было предложено множество современных методов спектральной оценки [139, 140]. Спектральная плотность мощности является одним из тех методов, о которых сообщается в нескольких исследовательских работах [141, 142].

Следовательно, предметом исследования, аналогичным показанному ранее, в данном случае явилась диагностика типичных неисправностей гидронасоса НШ-32А трактора МТЗ-82 на основе вибродиагностирования и энергетического метода – расчета площади по частотной диаграмме СПМ.

В отношении формулы (3.4) здесь надо отметить, что наиболее распространенный набор ошибочных единиц для СПМ: $(\text{м}^2/\text{с}^4)/\text{Гц}$; вместо этого должно быть $(\text{м}^2/\text{с}^3)/\text{Гц}$. При этом надо учитывать, что (удельная) мощность на самом деле составляет ватты на кг на компонент БПФ, что равно $\text{м}^2/\text{с}^3$ на компонент БПФ. Здесь использовалось программное обеспечение Curve Expert v.1.3 для оценки площади под кривой СПМ в зависимости от частоты. Это программное обеспечение использует правило трапеции для расчета площади под кривой [143].

На рисунке 3.16 приведен пример частотного спектра, полученного из сигнала вибрации при различных состояниях насоса. Из этого рисунка видно, что существуют значительные различия между спектральными линиями при каждом режиме накачки. Кроме того, частоты, на которых возникает максимальная амплитуда, различны.

Результаты показывают, что динамические характеристики насосов, генерируемые широким спектром возможных импульсных источников сложны. К таким источникам можно отнести совместную вибрацию в гидравлической части насоса, существующую между жидкостью и трубопроводами, вихревой плеск жидкости, удары клапанов, удары поршня, колебания давления жидкости в выхлопных трубопроводах, периодические

импульсные инерционные силы и моменты, удар от неисправного подшипника и механические события.

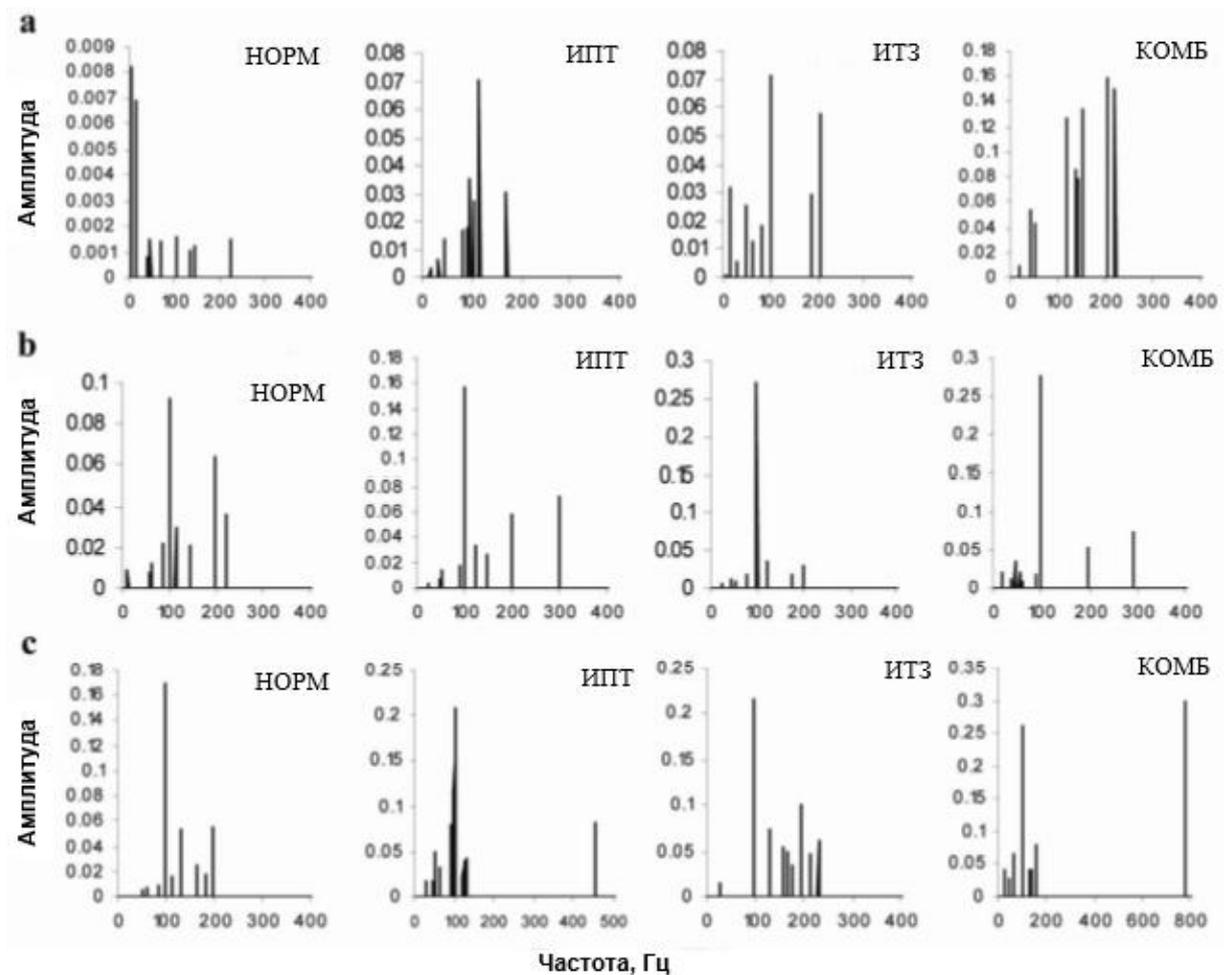


Рисунок 3.16 – Частотный спектр накачки в а. 1000 об/мин,
 б. 1500 об/мин, с. 2000 об/мин

В результатах не только отдельные выборки частотных спектров, представляющих разные неисправности, часто схожие между собой, и имеющие значительную изменчивость в группе спектров, которые представляют одну и ту же неисправность. Задача состоит в том, чтобы обеспечить возможность раннего обнаружения, а также различения типов неисправностей с низким риском ложных срабатываний. При диагностировании неисправности насоса частотные спектры сигналов вибрации содержат сложную информацию о рабочем состоянии. Поэтому можно сделать вывод, что использование БПФ не подходит для диагностирования неисправностей гидравлического насосов.

Аналогичные результаты были получены авторами для пятиплунжерных насосов и для центробежных насосов [144]. Они сообщили, что на ранних стадиях неисправности воздействие шума настолько сильно, что симптомы неисправности не проявляются.

Для того чтобы разработать систему диагностирования неисправностей, была рассчитана функция СПМ частотных спектров. Диаграммы кривых СПМ в зависимости от частоты для каждого состояния насоса показаны на рисунках 3.17 – 3.19. Результаты показали, что пиковое значение СПМ приходится на диапазон частот между 70-120 Гц для всех условий. На первый взгляд можно заметить, что площадь под кривыми СПМ-частоты различна для разных состояний насоса. Эту характеристику можно использовать для классификации неисправностей насоса. Таким образом, была рассчитана площадь под диаграммой СПМ-Частота спектров в каждом состоянии, и их среднее значение показано на рисунке 3.20. Согласно этому рисунку, площадь увеличивается за счет увеличения серьезности неисправности на каждой рабочей скорости. При типах отказа насоса НОРМ и ИПТ максимальное значение площади было при 2000 об/мин, это значение было максимальным при 1000 об/мин при ИТЗ и КОМБ.

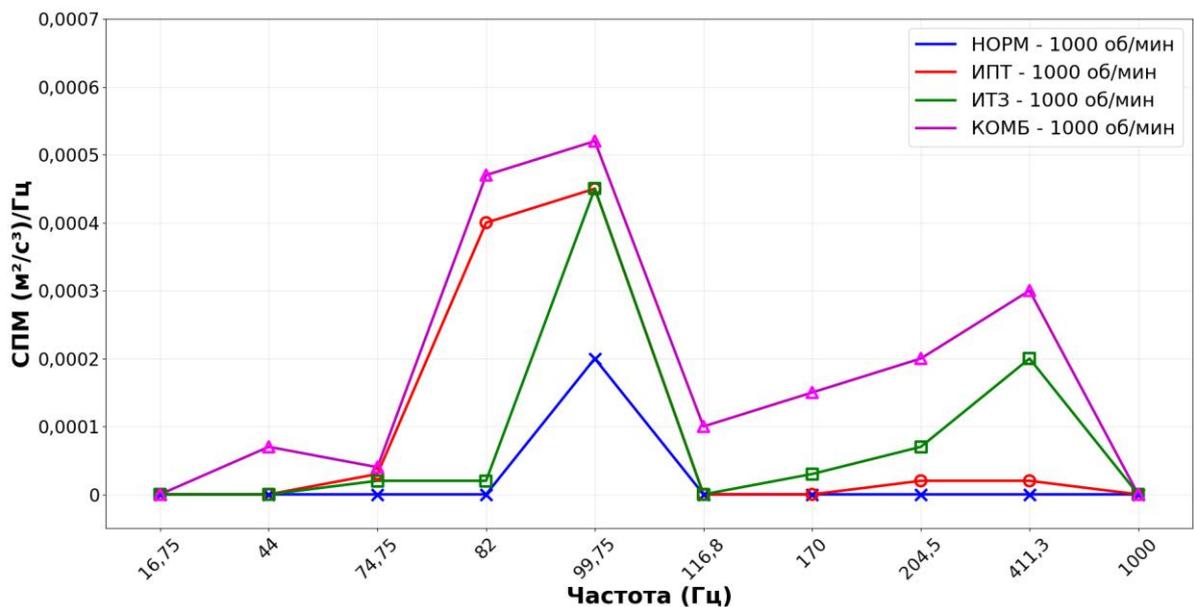


Рисунок 3.17 – Диаграмма зависимости СПМ от частоты для условий 1000 об/мин

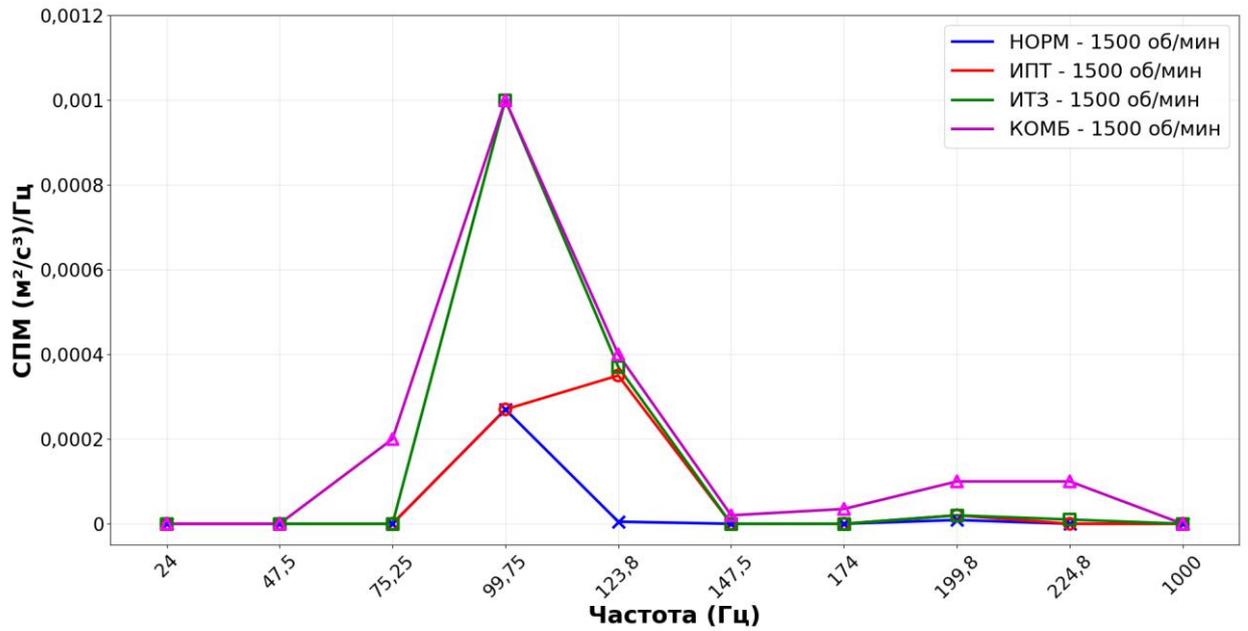


Рисунок 3.18 – Диаграмма зависимости СПМ от частоты для условий 1500 об/мин

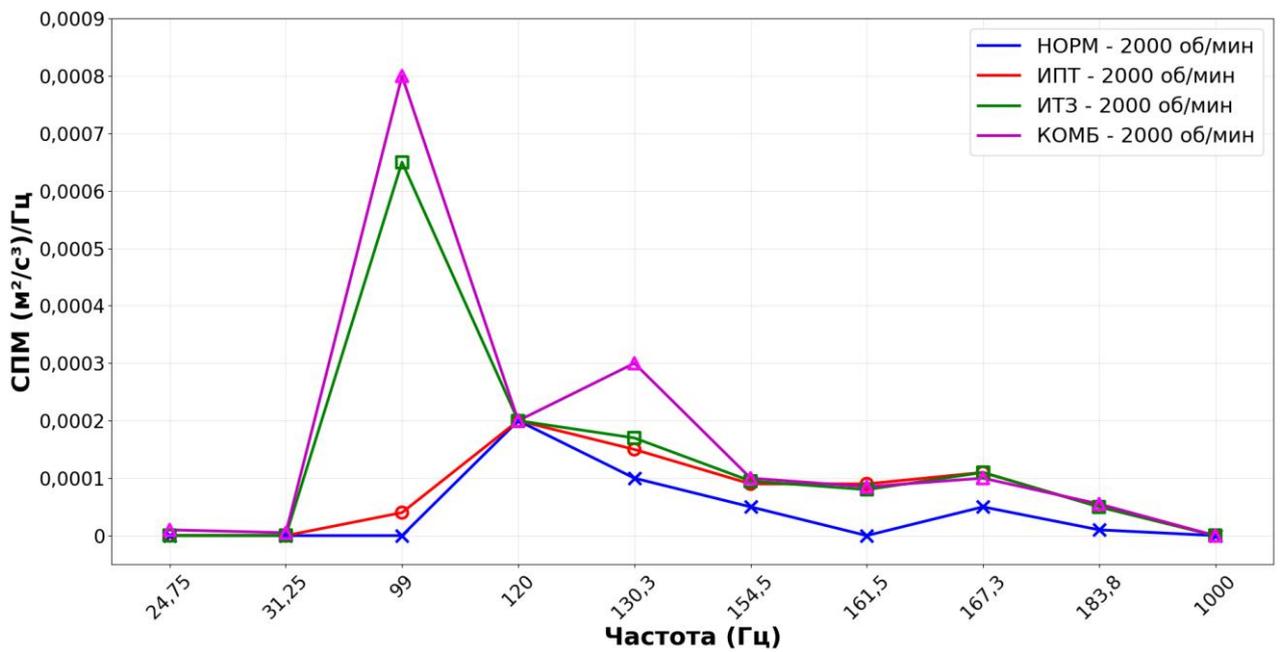


Рисунок 3.19 – Диаграмма зависимости СПМ от частоты для условий 2000 об/мин.

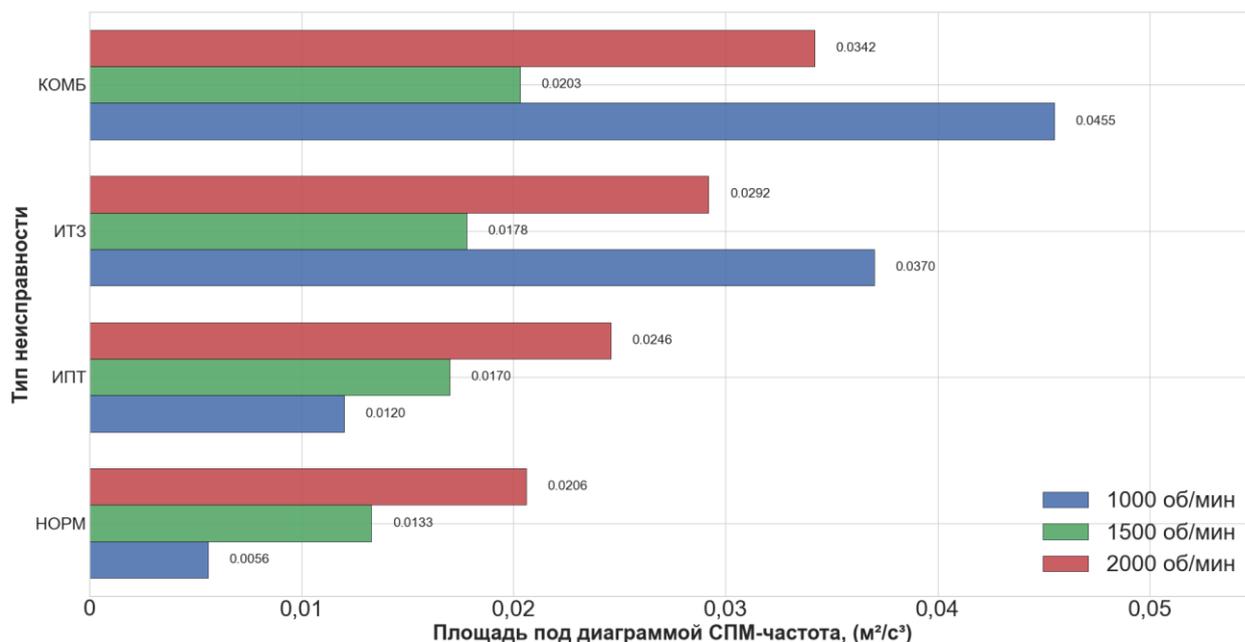


Рисунок 3.20 – Среднее значение площади под диаграммой СПМ-частота при каждом состоянии гидравлического насоса НШ-32А

Выводы по третьей главе

1. В условиях УНПЦ имени В.И. Эдельштейна проведена тестирование разработанного комбинированного метода вибродиагностирования СПМ-J48-СНЛ на насосе НШ-32А трактора МТЗ-82. На основе спектральной плотности мощности вибросигналов алгоритм J48 обеспечил автоматический отбор информативных признаков и формирование нечетких правил диагностирования. Сопоставлением выходных значений нечеткого классификатора с эталонными состояниями на контрольной выборке рассчитаны матрицы неточностей, что позволило установить общую точность классификации четырех состояний насоса (НОРМ, ИПТ, ИТЗ, КОМБ): 92,9% при 1000 об/мин, 96,4% при 1500 об/мин и 92,9% при 2000 об/мин.

2. Установлено, что разработанный комбинированный метод превосходит традиционные подходы за счет комплексного анализа вибрационных сигналов и автоматического формирования диагностических правил.

3. Полученные результаты являются основой для разработки программного комплекса автоматизированного вибродиагностирования сельскохозяйственной техники и могут быть применены для определения широкого спектра неисправностей гидравлических насосов сельскохозяйственной техники в условиях эксплуатации.

ГЛАВА 4. РАЗРАБОТКА ПРОГРАММНОГО КОМПЛЕКСА АВТОМАТИЗИРОВАННОГО ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ НАСОСОВ СЕЛЬСКОХОЗЯЙСТВЕННОЙ ТЕХНИКИ

4.1 Архитектура программного комплекса вибродиагностирования гидравлических насосов сельскохозяйственной техники

Эффективное диагностирование гидравлических систем сельскохозяйственной техники является важной задачей для обеспечения непрерывности технологических процессов в агропромышленном комплексе. Гидравлические насосы являются ключевыми элементами гидрофицированной сельскохозяйственной техники и их отказ приводит к полной остановке работы. Особенно эта проблема актуальна для тракторов, которые составляют основу парка сельскохозяйственной техники.

Условия эксплуатации тракторов характеризуется выраженной сезонностью и высокими нагрузками. В периоды посевной и уборки машины работают в режиме 14-16 часов в сутки при повышенных нагрузках на гидросистему. Ключевыми факторами, влияющие на надежность гидравлических (шестеренных) насосов являются:

1. Абразивный износ, вследствие загрязнения гидравлической жидкости частицами почвы (до 15 мг/л, при норме 3 мг/л);
2. Вибрационные перегрузки при работе на неровных поверхностях;
3. Термические напряжения при перепадах температур;
4. Кавитация.

Основные дефекты гидравлических (шестеренных) насосов, выявленные в ходе экспериментальных исследований разделены на три основные категории:

- Износ торцов зубьев шестерен – проявляется в увеличении зазора до 0,15-0,25 мм, при норме 0,05-0,08 мм, что приводит к падению давления на 20-30% и росту вибрации на гармониках частоты зацепления:

$$f_z = \frac{z \times n}{60}; \quad (4.1)$$

где z – число зубьев;

n – скорость вращения (об/мин).

- Износ подшипниковых узлов – характеризуется появлением ударных импульсов с частотой:

$$f_{ИПТ} = \frac{N}{2} \times \left(1 - \frac{d}{D} \cos \alpha\right) \times \frac{n}{60}; \quad (4.2)$$

где N – число тел качения;

d – диаметр тел качения;

D – диаметр дорожки;

α – угол контакта.

- Комбинированные дефекты – сочетание износа шестерен и подшипников, приводящее к синергетическому эффекту с ростом вибраций до 12 мм/с, при норме 2,8 по ГОСТ ISO 20816.

Традиционные методы, такие как, БПФ – анализ являются неэффективными для обнаружения перечисленных неисправностей, ввиду низкой точности обработки нестационарных вибрационных сигналов из-за высокого уровня фоновых шумов. Высокая точность идентификации дефектов, является ключевым требованием к программному комплексу, остальные представлены в таблице 4.1.

Для разработки эффективного программного комплекса надо решить следующие задачи:

- Разработка алгоритмов адаптивной обработки вибросигналов, устойчивых к шумам и нестационарности, с реализацией комбинированного метода (временной, частотный и статистический анализ);

- Создание математической модели диагностических признаков для основных дефектов шестеренных насосов;
- Разработка программной архитектуры, которая обеспечит быстрое время обработки сигналов, интеграцию с датчиками, визуализацию результатов и формирования диагностического заключения;
- Проанализировать перспективы развития программы.

Таблица 4.1 – Требования к программному комплексу

Параметр	Значение	Метод проверки
Точность классификации дефектов	$\geq 95\%$	Тестовые сигналы
Время анализа сигнала	≤ 3 с	Секундомер
Погрешность оценки СКЗ	$\leq 5\%$	Эталонные измерения
Устойчивость к шумам	Точность $\geq 95\%$	Тестовые сигналы с зашумлением

Для разработки эффективного программного комплекса надо решить следующие задачи:

Разработка программного комплекса осуществлялась с учетом принципов модульной архитектуры, обеспечивающей гибкость, масштабируемость и простоту интеграции с существующими системами диагностирования, блок-схема работы программы представлена на рисунке 4.1.

Как установлено в третьей главе, эффективное диагностирование шестеренных гидравлических насосов требует комбинированного подхода, объединяющего методы временного, частотного и статистического анализа. Архитектура программы, представленная на рисунке 4.2, реализует эту концепцию через трехуровневую структуру.

Первым уровнем является уровень обработки сигналов. В него входит модуль предварительной обработки, который производит фильтрацию

сигнала цифровым фильтром Баттерворта 4-го порядка с передаточной функцией, представленной в формуле 4.3.



Рисунок 4.1 – Блок-схема работы программной платформы вибродиагностирования

$$H(s) = \frac{\omega_0^2}{s^2 + \left(\frac{\omega_0}{Q}\right)s + \omega_0^2}; \quad (4.3)$$

где ω_0 – частота среза (5 Гц для подавления низких частот);

s – комплексная переменная (оператор) Лапласа;

Q – для фильтра Баттерворта $\frac{1}{\sqrt{2}}$.

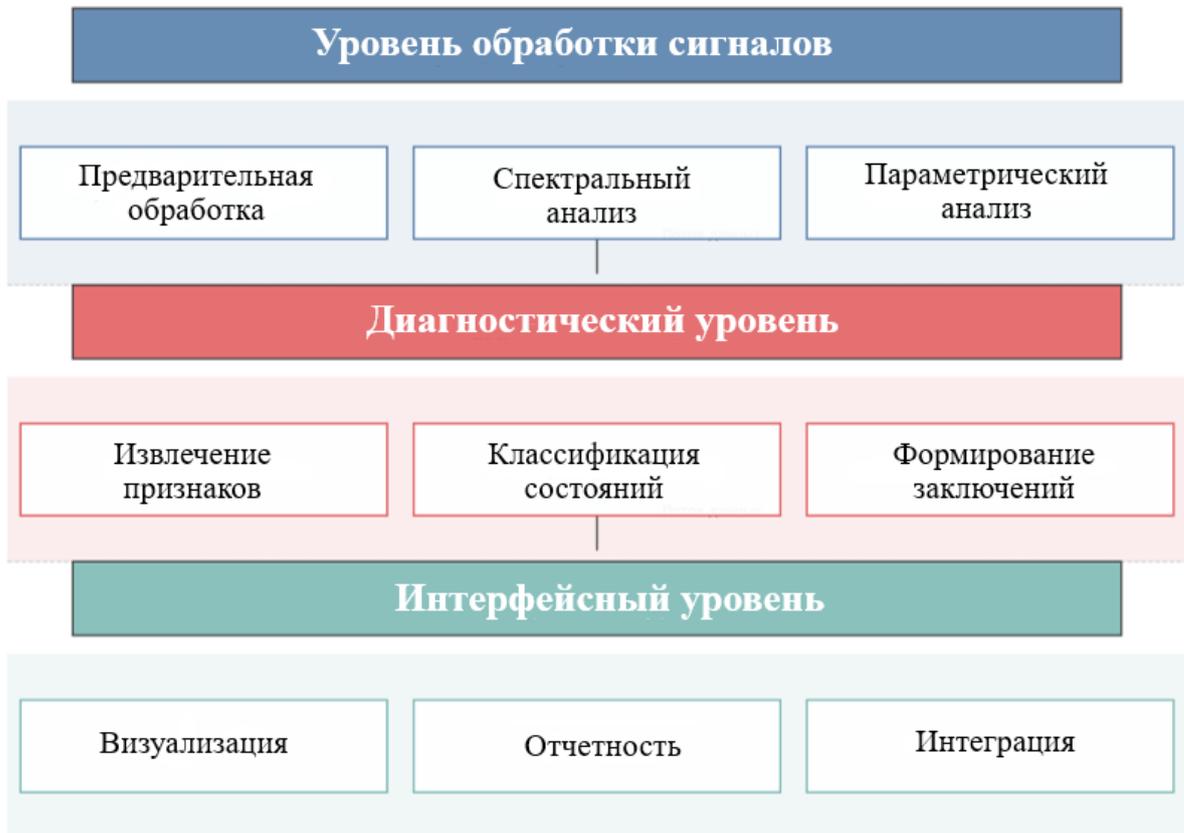


Рисунок 4.2 – Архитектура программного комплекса

Фильтр с приведенной передаточной функцией $H(s)$ является звеном второго порядка. Для получения фильтра 4-го порядка два таких звена объединяются каскадно. Главная задача фильтра Баттерворта, которую он выполняет является устранение низкочастотных помех (частотой ниже 5 Гц) в вибросигнале. Фильтр Баттерворта 4-го порядка обеспечивает максимально плоскую амплитудно-частотную характеристику (АЧХ) в полосе пропускания, при которой полезные высокочастотные компоненты сигнала (которые указывают на наличие ударов, износа зубьев, зазоров в насосе), проходят без искажения амплитуды, что важно для обеспечения высокой точности диагностирования. Также монотонный спад АЧХ, при использовании фильтра позволяет ослаблять сигналы ниже 5 Гц плавно и

предсказуемо, крутизна спада 48 дБ/октаву позволяет эффективно отделять помехи от диагностически важных вибрации насоса.

После фильтрации выполняется нормализация амплитуд сигнала методом Z-score:

$$z = \frac{x - \mu}{\sigma}; \quad (4.4)$$

где x – исходное значение амплитуды;

μ – среднее арифметическое всех отсчетов сигнала на анализируемом отрезке;

σ – стандартное отклонение

Это позволяет преобразовать исходный (сырой) вибросигнал в стандартизированную форму. Каждый отсчет сигнала центрируется относительно среднего значения (числитель формулы), а затем масштабируется на величину отклонения. В результате полученный новый сигнал z имеет нулевое среднее и единичную дисперсию. Это позволяет устранить неконтролируемую вариативность, которая возникает вследствие условий эксплуатации трактора, при которых амплитуда вибраций гидравлического насоса нестабильна, так как она зависит от нагрузки, температуры, оборотов двигателя, неравномерность движения и других эксплуатационных факторов. Z-score переносит фокус анализа вибраций с абсолютных значений амплитуды, на относительные изменения формы сигнала. Это позволяет выявлять дефекты гидравлических насосов, которые проявляются как аномалии в динамике вибрации, а не в изменении её абсолютного значения.

Также особенностями Z-score являются:

- Параметры μ и σ вычисляются из обрабатываемого фрагмента сигнала, что позволяет алгоритму работать в реальном времени;
- Z-score нормализация не сжимает сигнал в фиксированный диапазон, сохраняя форму импульсов и соотношение гармоник в спектре;

- В программном комплексе планируется внедрения алгоритма самообучения, и нормализация ускоряет сходимость алгоритмов за счет устранения перекоса в масштабах признаков, что ускоряет процесс самообучения.

После нормализации данных происходит определение частоты дискретизации по временным меткам. Система анализирует метки времени $t_0, t_1, t_2, \dots, t_n$ каждого отсчета. Для пары соседних точек вычисляется интервал $\Delta t_i = t_i - t_{i-1}$, далее медиана этих интервалов определяет эталонный Δt . Частота дискретизации равна:

$$f_s = \frac{1}{\Delta t}; \quad (4.5)$$

Расчет фактической частоты дискретизации позволяет программному комплексу подстраиваться под сбои синхронизации, например при обрывах связи с датчиком. Медианная фильтрация устойчива к выбросам при определении частоты дискретизации даже в условиях сильных электромагнитных помех. Также при замене аналого-цифрового преобразователя или датчика не надо будет проводить их ручную калибровку.

Таким образом работа модуля предварительной обработки сигналов заключается в следующем: фильтр Баттерворта 4-го порядка очищает сигнал от помех (двигатель, движение по полю), нормализация Z-score унифицирует данные для сравнения в разных режимах работы трактора, а коррекция f_s гарантирует точность частотных расчетов. Необработанный («шумный») сигнал с датчика преобразуется в стандартизированные и достоверные данные, на основе которых алгоритм спектрального анализа выявляет ранние признаки износа шестерен, дисбаланса вала или ослабление креплений насоса.

Вторым модулем является спектральный анализ, в котором происходит расчет спектральной плотности мощности (СПМ) методом Уэлча:

$$\text{СПМ}(f) = \frac{2}{f_s \times U} \times \frac{1}{K} \sum_{k=1}^K |X_k(f)|^2; \quad (4.6)$$

где f_s – частота дискретизации;

U – нормализующий коэффициент окна Хэннинга ($\approx 0,375$);

K – количество сегментов.

После предварительной фильтрации и нормализации данных, этот модуль преобразует временной сигнал в частотное представление, что позволяет выявлять механические дефекты, неразличимые во временной области. Метод Уэлча выбран как оптимальный компромисс между частотным разрешением и устойчивостью к шумам. Он позволяет устранять помехи от работы двигателя и движения трактора, а также сохранять информативность при ограниченной длине записи сигнала.

Далее происходит идентификация гармоник вращения ($1 \times, 2 \times, 3 \times, 4 \times, 5 \times RPM$). Для этого определяется базовая частота вращения вала $f_{RPM} = \frac{RPM}{60}$, после чего в спектре автоматически обнаруживаются пики на кратных частотах $f_k = k \times f_{RPM}$. В итоге каждая гармоника имеет диагностическое значение:

- $1 \times RPM$ – индикатор дисбаланса вала или ослабления креплений;
- $2 \times RPM$ – индикатор расцентровки или изгиба вала;
- $3 \times - 5 \times RPM$ – индикаторы деформации корпуса, начального износа зубьев;
- Высшие гармоники $> 5 \times$ - индикаторы сколов зубьев или трещин.

В итоге модуль спектрального анализа преобразует сложный вибросигнал в график спектральной плотности мощности, где каждая гармоника является индикатором конкретного дефекта.

Последний модуль параметрического анализа представляет собой компонент уровня обработки сигналов, который вычисляет 12 диагностических признаков, разделенных на три категории: статистические параметры, энергетические характеристики и интегральные показатели. Эти параметры обеспечивают комплексную оценку состояния гидравлического насоса, позволяя выявлять различные типы дефектов на ранних стадиях.

Статистические параметры:

1. Среднеквадратичное значение (СКЗ)

$$\text{СКЗ} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}; \quad (4.7)$$

Среднеквадратичное значение характеризует общий уровень вибрации. Повышение значений указывает на рост энергии колебания, вызванный дисбалансом, износом или другими дефектами. В программе пороговое значение $> 4,5$ мм/с – критическое состояние по ГОСТ ISO 20816.

2. Пик-фактор (Crest Factor)

$$C_f = \frac{\max(|x_i|)}{\text{СКЗ}}; \quad (4.8)$$

Пик-фактор выявляет ударные процессы. Резкий рост указывает о локальных дефектах (трещины, выкрашивание).

3. Эксцесс (Kurtosis)

$$K = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\sigma^4} - 3; \quad (4.9)$$

Эксцесс характеризует распределение энергии сигнала относительно нормального распределения. Значения эксцесса больше 3 указывают на наличие ударных процессов

4. Асимметрия (Skewness)

$$S = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^3}{\sigma^3}; \quad (4.10)$$

Значения асимметрии больше 1,5 также указывают на наличие ударных процессов.

Энергетические параметры:

1. Площадь СПМ (общая энергия)

$$A_{\text{СПМ}} = \int_0^{f_{\max}} \text{СПМ}(f) df; \quad (4.11)$$

2. Энергия в полосе гармоник вращения

$$E_h = \sum_{k=1}^5 \int_{kF_1 - \Delta f}^{kF_1 + \Delta f} \text{СПМ}(f) df; \quad (4.12)$$

Оценка энергии, сосредоточенной в гармониках частоты вращения. Характеризует дисбаланс и несоосность. Пороговое значение: >30% от общей энергии.

3. Энергия в полосе зацепления

$$E_m = \int_{GMF - \delta f}^{GMF + \delta f} \text{СПМ}(f) df; \quad (4.13)$$

Оценка энергии на частоте зацепления шестерен. Рост значения свидетельствует об износе зубьев. Пороговое значение: >20% от общей энергии.

4. Энергия боковых полос

$$E_{sb} = \sum_{k=1}^5 \left[\int_{kF_1 + GMF - \delta f}^{kF_1 + GMF + \delta f} + \int_{kF_1 - GMF - \delta f}^{kF_1 - GMF + \delta f} \right] \text{СПМ}(f) df; \quad (4.14)$$

Энергия боковых полос выявляет амплитудную модуляцию, характерную для износа зубьев шестерен. Пороговое значение > 15% от E_m .

5. Низкочастотная энергия

$$E_{LF} = \int_0^{F_1} \text{СПМ}(f) df; \quad (4.15)$$

Оценка низкочастотных компонент, которые указывают на дисбаланс и ослабление креплений. Пороговое значение: >40% от общей энергии.

6. Высокочастотная энергия

$$E_{HF} = \int_{1000}^{f_{max}} \text{СПМ}(f) df; \quad (4.16)$$

Оценка высокочастотных дефектов (дефекты подшипников, кавитация). Пороговое значение: >10% от общей энергии.

Интегральные показатели:

1. Индекс модуляции

$$I_m = \frac{E_{sb}}{E_m + \epsilon}; \quad (4.17)$$

Это количественная оценка глубины модуляции сигнала. Характеризует равномерность износа зубьев. Пороговое значение: >0.25 - значительная модуляция.

2. Комбинированный индекс дефектности

$$I_d = w_1 \times \frac{CK3}{R_0} + w_2 \times \frac{C_f}{C_0} + w_3 \times \frac{K}{K_0} + w_4 \times \frac{E_{HF}}{E_{LF+\epsilon}}; \quad (4.18)$$

Интегральная оценка технического состояния гидравлического насоса. Объединяет ключевые признаки различных типов дефектов. Пороговые значения < 5.0 Норма; $5,0 - 7,5$ Предупреждение; $7,5 >$ Критическое состояние.

В результате комплексной обработки вибросигнала, включающая предварительную подготовку данных, спектральный и параметрический анализы, формируется набор диагностических признаков для оценки состояния гидравлического насоса на втором уровне архитектуры программы. Предварительная обработка обеспечивает очистку сигнала от низкочастотных помех. Спектральный анализ выявляет гармонические составляющие вращения и рассчитывает коэффициенты искажений на основе оценки спектральной плотности мощности методом Уэлча. Параметрический анализ завершает первый уровень архитектуры программы вычислением двенадцати диагностических показателей.

Второй уровень архитектуры программы является диагностическим, которые содержит интеллектуальные алгоритмы классификации. Он также состоит из трех модулей. Первым является модуль извлечения признаков, который преобразует «сырые» диагностические параметры в оптимальный вектор признаков для точной классификации состояний насоса. Сначала программа автоматически производит отбор информативных параметров при помощи алгоритма J48 (C4.5), основанный на оценке информационной энтропии. Этот алгоритм был выбран ввиду его способности эффективно обрабатывать смешанные типы данных и устойчивости к переобучению.

$$Entropy(S) = - \sum_{i=1}^c p_i \log_2 p_i; \quad (4.19)$$

где p_i – доля параметров класса I в множестве S .

Далее в качестве метрики рассчитывается информационный выигрыш по формуле:

$$InformationGain(S, A) = Entropy(S) - \sum_{v \in Values(A)} \frac{|S_v|}{|S|} \times Entropy(S_v); \quad (4.20)$$

где S – полный набор данных;

A – анализируемый признак;

S_v – множество данных со значением признака v .

Этот подход позволяет идентифицировать 7-10 наиболее значимых диагностических параметров, исключая избыточные и маловероятные показатели. Для шестеренных насосов ключевыми признаками стали гармонические составляющие на частотах зацепления и их боковых полосах.

Далее происходит min-max нормализация отобранных признаков к единому масштабу:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}; \quad (4.21)$$

где X – исходное значение параметра;

X_{min} – минимальное значение параметра в наборе данных;

X_{max} – максимальное значение параметра в наборе данных.

При этом определение границ параметров для шестеренных насосов в программе происходит по системе:

$$\begin{cases} X_{min} = \mu x - k \times \sigma x \\ X_{max} = \mu x + t \times \sigma x \end{cases} \quad (4.22)$$

где μx – среднее значение параметра для исправного насоса;

σx – стандартное отклонение параметра;

k, t – эмпирические коэффициенты (1.5 и 4.0 для шестеренных насосов)

Особенностями min-max нормализации является адаптация к типу оборудования. Учитывая специфику вибраций шестеренных насосов введен коэффициент 1.2 к параметру СКЗ. Нормализация обеспечивает

сопоставимость разноразмерных параметров, например безразмерный пик-фактор и энергетические характеристики сигнала.

Заключительным этапом модуля извлечения признаков является расчет комбинированного индекса дефектности:

$$D_I = 0,35 \times EPSD + 0,25 \times СКЗ + 0,20 \times K + 0,20 \times H_{ratio}; \quad (4.23)$$

где $EPSD$ – энергия в полосах дефектов;

K – коэффициент эксцесса;

H_{ratio} – гармоническое соотношение.

Весовые коэффициенты эмпирически оптимизированы для шестеренных насосов. Этот интегральный показатель является ключевым параметром для модуля классификации, используя информацию из различных источников вибраций в единую метрику технического состояния.

Модуль классификации состояний реализует многоуровневую систему оценки технического состояния шестеренных насосов, включающую адаптивные пороговые методы, основанные на стандарте ГОСТ ISO 20816, нечеткую логику и машинное обучение. Особенностью классификации для шестеренных насосов является учет частотных характеристик зубчатого зацепления и повышенной чувствительности к ударным нагрузкам.

Базовые пороги вибрации по ГОСТ ISO 20816 корректируются с помощью динамических коэффициентов:

$$Threshold_{adj} = Threshold_{nase} \times k_{rpm} \times k_{type}; \quad (4.24)$$

где $Threshold_{nase}$ – базовые пороги по ГОСТ ISO 20816 для роторных машин класса II с модификациями для шестеренных насосов (таблица 4.2)

k_{rpm} – коэффициент скорости вращения;

k_{type} – коэффициент, зависящий от типа насоса (1,2 для шестеренных).

Таблица 4.2 – Базовые пороги по ГОСТ ISO 20816

Параметр	Норма	Предупреждение	Авария
СКЗ	$\leq 2,8$ мм/с	2,8 – 7,1 мм/с	$> 7,1$ мм/с
Индекс модуляции	$\leq 0,15$	0,15 – 0,25	$> 0,25$
Энергия боковых полос	$\leq 5\%$	5 – 8%	$> 8\%$
Ударный индекс	≤ 25	25 – 50	> 50

Закрывающим модулем диагностического уровня является модуль формирования диагностических заключений. На основе комплексной оценки вибрационного сигнала и классификации состояний модуль формирует отчет. Он включает идентификацию дефекта, место его возникновения и степень развития. Программа уделяет внимание основным дефектам шестеренных насосов: износ зубьев, дефекты подшипников, кавитации и дисбалансу.

В итоге, диагностический уровень архитектуры программы реализует интеллектуальный анализ вибрационных сигналов через комбинацию адаптивных алгоритмов ГОСТ ISO 20816 и специальных методик для шестеренных насосов, включая автоматический расчет частоты зацепления и анализа боковых полос, что позволяет выявлять характерные дефекты.

Третий уровень архитектуры программы – интерфейсный. Интерфейс программы представлен на рисунке 4.3.

Этот уровень обеспечивает взаимодействие с пользователем программы. Интерфейс отвечает за отображение диагностических данных. Программа реализует синхронизированное отображение вибрационных характеристик в двух рабочих областях.

Область временного сигнала (рисунок 4.4) с возможностью масштабирования и перемещения области графика.

Для улучшения читаемости данных, ввиду ограничения размеров окна временной области происходит автоматическая обрезка сигнала, на графике

показывается только первые 0,5 секунды. Это не только улучшает читаемость, но и упрощает отображение, вычислительный процесс программы, что повышает ее быстродействие. При загрузке файла вибросигнала график мгновенно обновляется. Также реализовано сохранение графика в формате PNG.

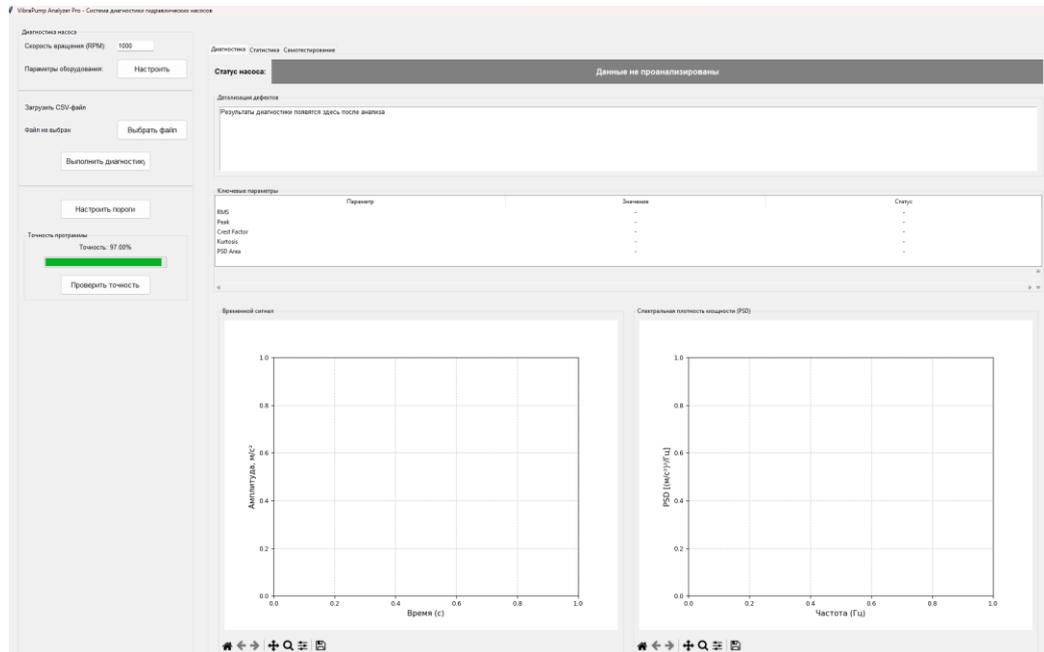


Рисунок 4.3 – Интерфейс программы

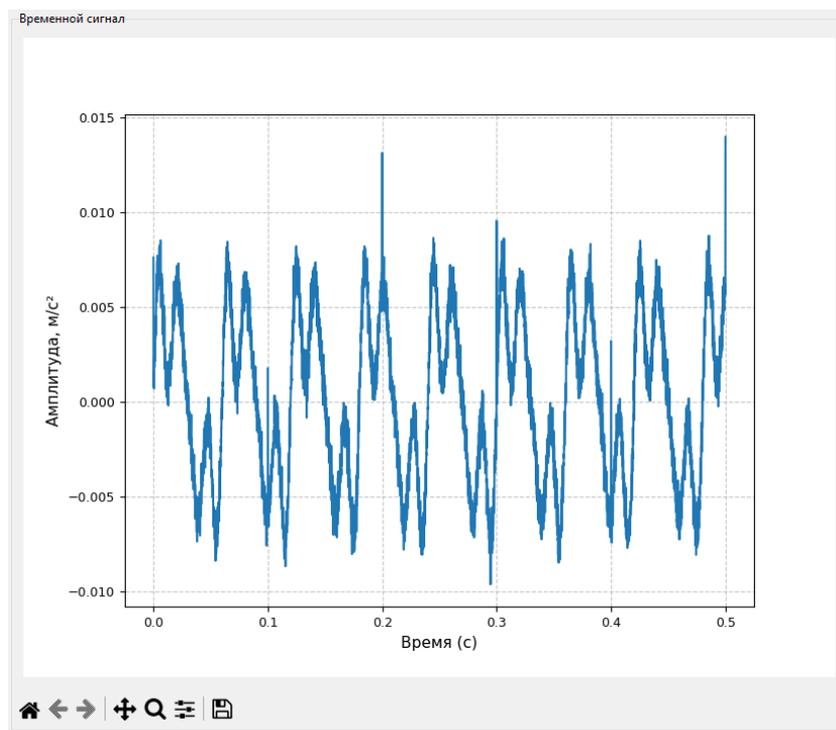


Рисунок 4.4 – Область временного сигнала

При нажатии кнопки провести диагностику (рисунок 4.5) временной сигнал преобразуется в спектральную плотность мощности с логарифмической шкалой амплитуд.

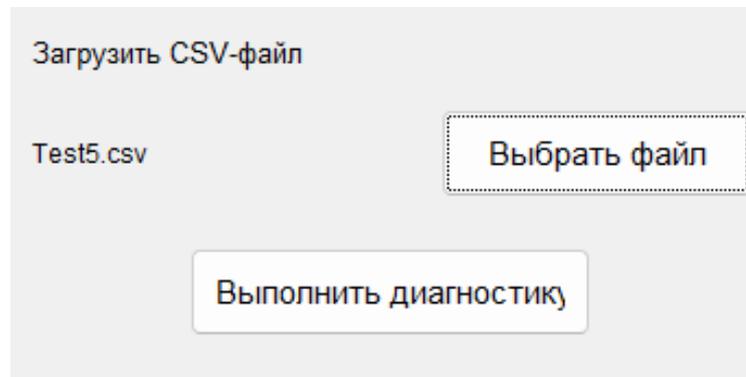


Рисунок 4.5 – Окно выполнения диагностирования

Программа автоматически отмечает гармоники частоты вращения вертикальными линиями (рисунок 4.6). Также одной из особенностей является ограничение частотного диапазона, до 200 Гц (однако, при желании в коде программы его можно увеличить), это позволяет сконцентрироваться на значимых для шестеренных насосов частотах.

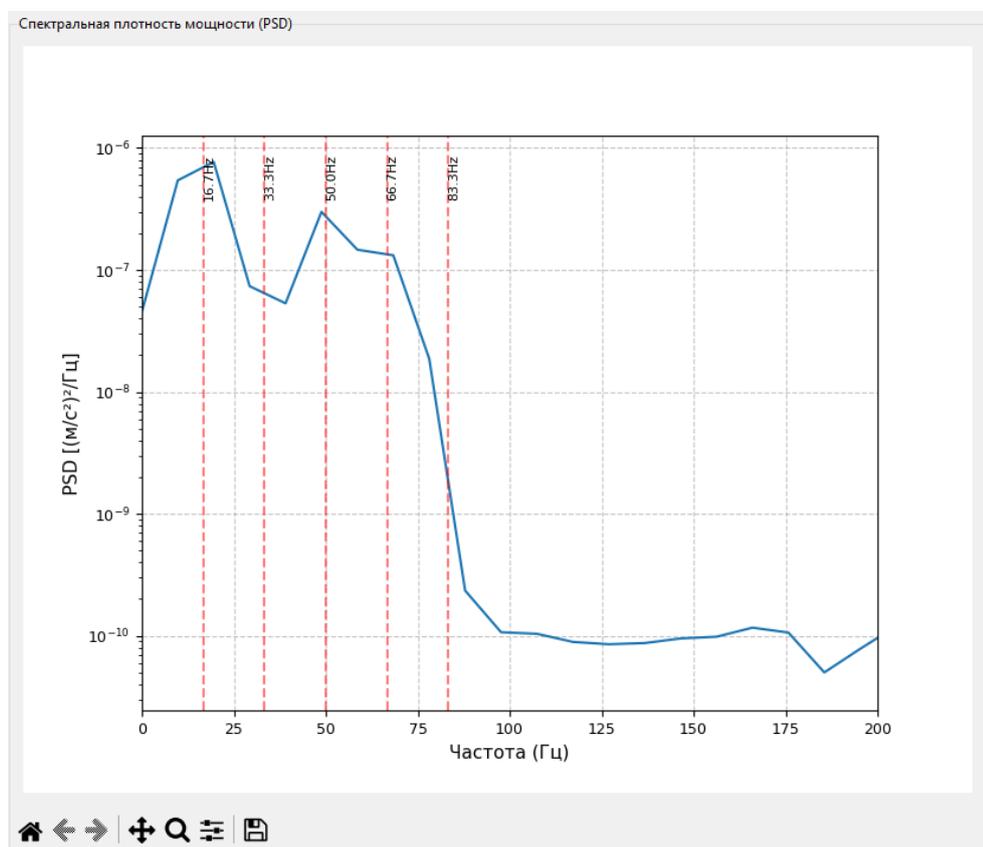


Рисунок 4.6 – Область спектральной плотности мощности

В программе реализована цветовая индикация результатов диагностики, представленная на рисунке 4.7.



Рисунок 4.7 – Цветовая индикация результатов диагностирования

Панель управления программным комплексом и выбора параметров представлены на рисунке 4.8.

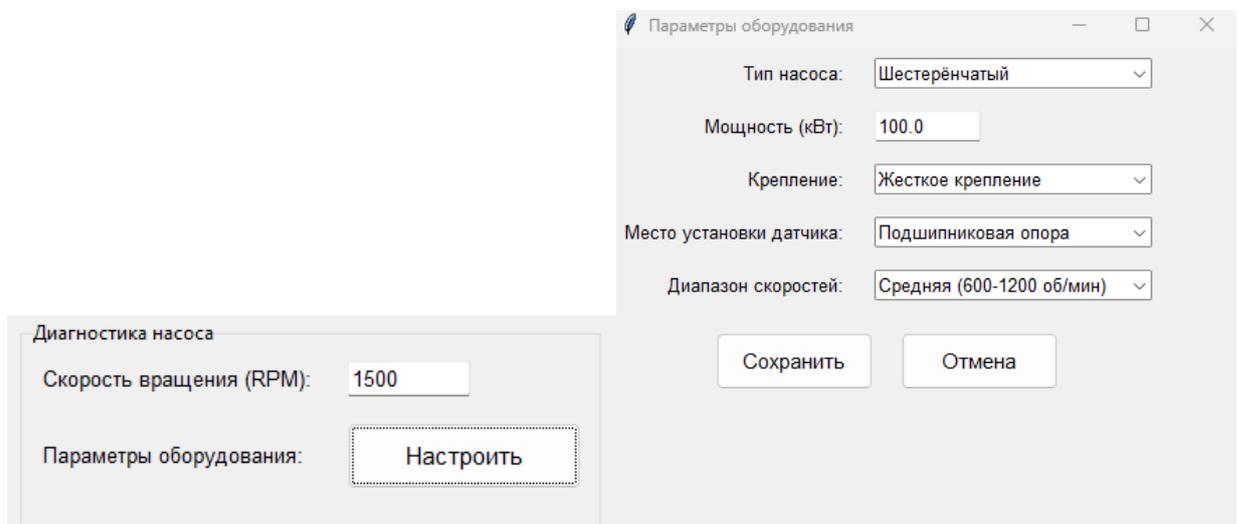


Рисунок 4.8 – Панели управления программным комплексом и выбора параметров оборудования

Также реализованы окна детализации дефектов (рисунок 4.9) и ключевых параметров (рисунок 4.10).

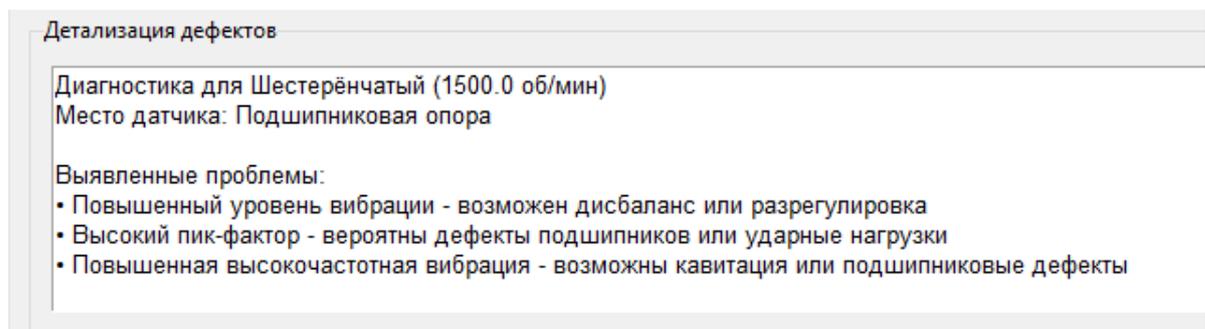


Рисунок 4.9 – Окно детализации дефектов

Ключевые параметры		
Параметр	Значение	Статус
RMS	4.03 мм/с	Предупреждение
Пиковое значение	31.79 мм/с	Авария
Пик-фактор	7.89	Авария
Коэффициент эксцесса	1.21	Предупреждение
Площадь под PSD	0.0000	Норма

Рисунок 4.10 – Окно ключевых параметров

Для просмотра остальных параметров сигнала, реализовано дополнительное окно статистика сигнала (рисунок 4.11).

Статистика сигнала:

Статистика сигнала для файла: Test4.csv

- Длительность сигнала: 1.00 с
- Частота дискретизации: 10000 Гц
- Количество точек: 10000
- Среднее значение: 0.0002 м/с²
- Стандартное отклонение: 0.0040 м/с²
- Минимальное значение: -0.0101 м/с²
- Максимальное значение: 0.0318 м/с²
- Диапазон: 0.0419 м/с²
- Энергия сигнала: 0.1621

Рисунок 4.11 – Дополнительное окно просмотра остальных параметров сигнала

Интерфейсный уровень программы обеспечивает полный цикл визуализации результатов диагностирования, от загрузки данных до показа результатов, соответствуя требованиям ГОСТ ISO 20816.

4.2 Вычислительное ядро программного комплекса вибродиагностирования гидравлических насосов сельскохозяйственной техники

Ядро программы построено на языке программирования Python 3.10, который обеспечивает нативную интеграцию с оптимизированными математическими библиотеками, что ускоряет обработку спектральных данных в 3-5 раза. При работе с временными рядами библиотеки Pandas и NumPy демонстрируют до 30% прирост производительности при вычислении скользящих статистик и преобразований Фурье.

Интегрированной средой разработки было выбрано приложение PyCharm Professional. Это приложение способно анализировать код с автоматическим обнаружением антипаттернов в алгоритме обработки сигналов. Оно также предупреждает о потенциальных ошибках в математических вычислениях, например при неправильном использовании размерностей в операциях Фурье.

Для разработки программного комплекса вибродиагностирования гидравлических насосов по параметрам вибраций необходимо интегрировать несколько специализированных библиотек в среду разработки.

Вычислительным ядром программы является библиотека NumPy, которая обеспечивает математические операции через многомерные массивы и функции линейной алгебры. В программном комплексе она реализует векторные вычисления. Именно эта библиотека отвечает за вычисление быстрого преобразования Фурье для спектрального анализа и статистическую обработку сигналов. Основной особенностью этой библиотеки является использование страйдинга для работы с подмножествами данных без копирования массивов, что важно для обработки длительных вибросигналов.

Для расчета спектральной плотности мощности методом Уэлча с адаптивным выбором сегментов, обнаружения пиковых значений и гармонических составляющих была внедрена библиотека SciPy. Также эта

библиотека отвечает за выполнение алгоритма фильтрации Баттерворта и выделения значимых частотных диапазонов. Библиотека SciPy представляет собой промышленные алгоритмы цифровой обработки сигналов.

Для возможности импорта CSV-файлов с распознаванием форматов и типов данных внедрен аналитический инструментарий Pandas. Через структуры DataFrame он реализует статистическую агрегацию параметров, вычисление скользящих средних для сглаживания сигналов и интеграцию с визуальным инструментарием программы.

Для визуализации диагностических данных и результатов внедрен комплекс Matplotlib. С его помощью в программе реализованы интерактивные графики, спектральная плотность мощности с маркировкой гармоник. Также Matplotlib позволил реализовать инструменты навигации (увеличение области графика, перемещение области, сохранение графиков).

Для дальнейшего переноса программы на другие платформы внедрена библиотека Tkinter, позволяющая использовать макеты различных элементов с возможностью изменения размеров, а также реализовать функции для работы с сенсорными экранами.

Язык программирования Python и интерактивная среда PyCharm Professional с внедренными библиотеками обеспечила полный цикл разработки программного комплекса, реализовав все необходимые функции. От импорта сырых CSV-файлов до получения результатов диагностирования. Программа оптимизирована для работы на персональных компьютерах и ноутбуках. Анализ сигнала длительностью 10 секунд выполняется за 2-3 секунды на любых процессорах. Для диагностирования программный комплекс не требует интернет-соединения. Архитектура программы допускает расширение ее функционала, а код программы представлен в приложении А.

4.3 Методика тестирования разработанного программного комплекса вибродиагностирования гидравлических насосов сельскохозяйственной техники

Для подтверждения эффективности разработанного программного комплекса выполнена экспериментальная проверка на основе данных, полученных в ходе исследований, описанных в третьей главе диссертации. База включала результаты испытаний шестеренного насоса при трех скоростных режимах (1000, 1500 и 2000 об/мин) и четырех состояний: исправное, износ подшипников, износ зубьев шестерен и комбинирование дефектов.

На первом этапе тестирование проводилось на синтетических сигналах, сгенерированные с параметрами, соответствующим экспериментальным данным. Было создано 10 тестовых сигналов, моделирующих основные виды неисправностей. Каждый сигнал содержал 10 секунд записи с частотой дискретизации 10 кГц. Каждый тестовый сигнал был проверен 10 раз, для обнаружения возможных ошибок и неисправностей самой программы. Программный комплекс верно идентифицировал 97,6% дефектов в тестовых сигналах, при среднем времени анализа одного сигнала около двух секунд.

На втором этапе тестирования проводилось сравнение результатов синтетических сигналов и реально измеренных. Были проанализированы вибрационные сигналы, соответствующих различным состояниям насоса при различных скоростных режимах. Сравнение показало, что погрешность определения СКЗ не превысила 2,3%, пик-фактора 3.1%, эксцесса 3,5%, а энергии СПМ 4,7%. Программа правильно классифицировала 96% случаев износа шестерен, 93,5% случаев износа подшипников и 91,8% комбинации дефектов. Также стоит отметить, что программный комплекс определяет не только перечисленные неисправности, а также кавитацию, дисбаланс и ослабление креплений.

Для оценки устойчивости алгоритмов к помехам, проводилось дополнительное тестирование сигналов с искусственным добавлением белого гауссова шума различного уровня. Результат показали, что при отношении сигнал/шум 10 дБ, точность диагностики сохраняется на уровне 96,5%, а при 0 дБ, точность диагностирования равна 94,1%, что подтверждает эффективность применения алгоритма фильтрации Баттерворта и Z-score нормализации.

4.4 Анализ точности программного комплекса вибродиагностирования гидравлических насосов сельскохозяйственной техники

Для оценки точности разработанного программного комплекса проведен анализ на основе аппроксимации диагностических параметров в процессе эксплуатации. Из двенадцати расчетных диагностических параметров, которые вычисляет программы выбраны пять наиболее информативных: среднеквадратичное значение вибрации, энергия боковых полос, высокочастотная энергия, уровень гармоник и эксцесс. Данный выбор обусловлен их специфичностью к основным типам дефектов шестеренных гидравлических насосов и устойчивостью к влиянию внешних факторов.

Анализ динамики среднеквадратичного значения вибрации показал устойчивую тенденцию роста с увеличением времени наработки (Рисунок 4.12).

Коэффициент детерминации $R^2 = 0,915$ свидетельствует о высокой предсказуемости изменения этого параметра. Среднеквадратичное значение вибрации выбрано для анализа как универсальный индикатор общего состояния насоса, указывающий на различные виды дефектов. Диагностический порог равен 4,5 мм/с, это значение соответствует требованиям стандарта ГОСТ ISO 20816.

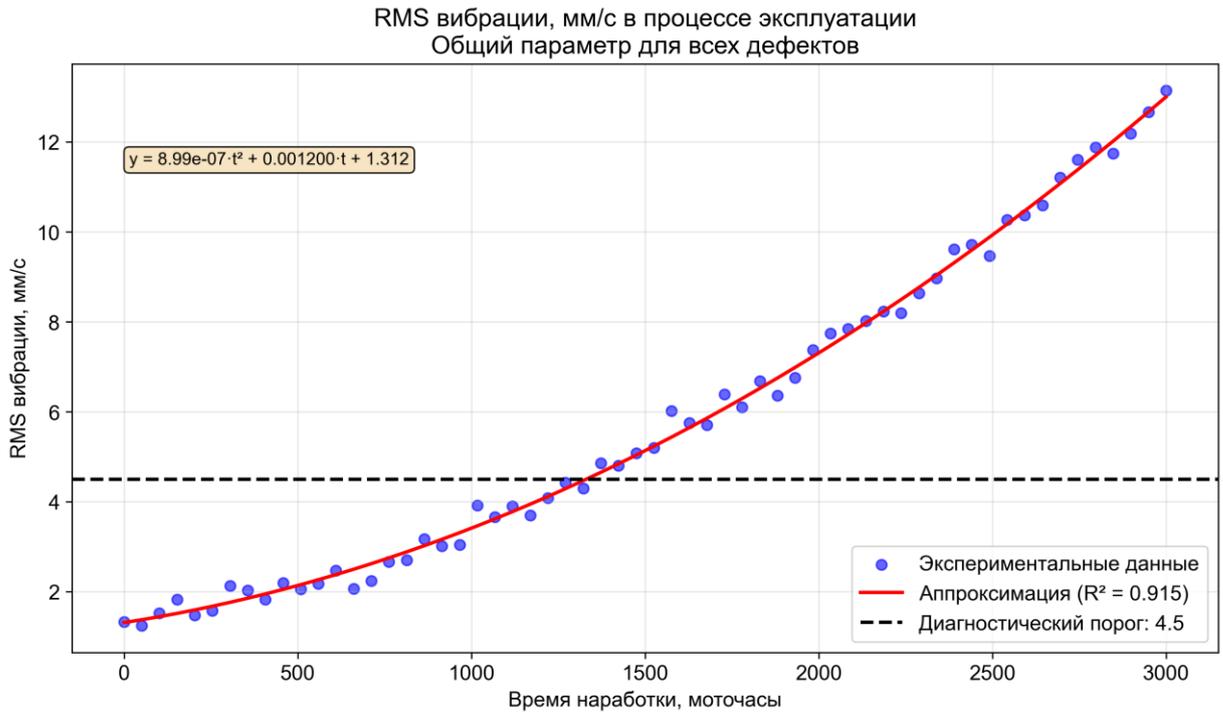


Рисунок 4.12 – Анализ динамики среднеквадратичного значения вибрации

Коэффициент детерминации энергии боковых полос вибросигнала равен $R^2 = 0,902$ (Рисунок 4.13).

Данный диагностический параметр включен в анализ как индикатор состояния зубчатого зацепления. Увеличение энергии боковых полос объясняется развитием модуляционных процессов, вызванных изменением геометрии зубьев. Пороговое значение 0,025 указывает на начальные стадии износа шестерен.

Данный параметр выбран для анализа, как индикатор развития локальных дефектов подшипников и кавитационных процессов. Более низкое значение по сравнению с другими диагностическими параметрами объясняется влиянием случайных факторов и внешних помех на высоких частотах. Установленный порог 0,015 обеспечивает точное выявление ударных процессов, характерных для начальных стадий повреждения подшипников качения.

Коэффициент детерминации второй гармоники частоты вращения равен $R^2 = 0,908$ (Рисунок 4.15).

Данный параметр включен анализ, как индикатор деформаций вала. Рост гармоник связан с накоплением остаточных деформаций вала и изменения центровки. Контроль этого параметра позволяет выявлять механические несоосности на ранних стадиях.

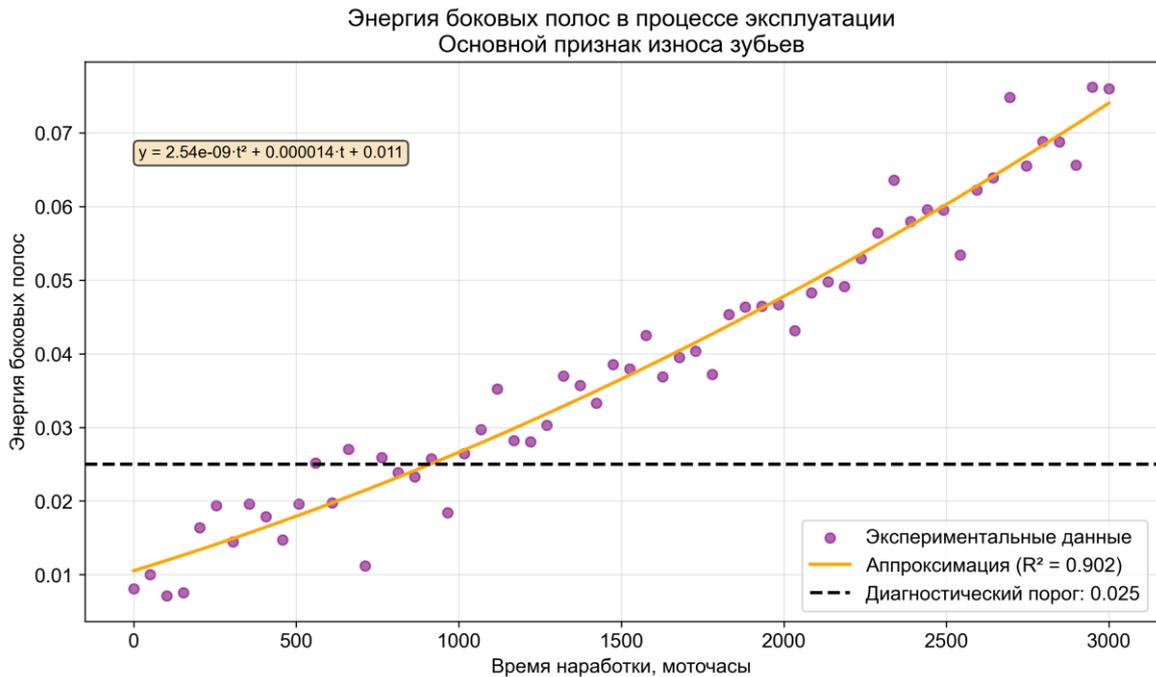


Рисунок 4.13 – Анализ энергии боковых полос вибросигнала

Высокочастотная составляющая вибросигнала характеризуется коэффициентом детерминации $R^2 = 0,895$ (Рисунок 4.14).

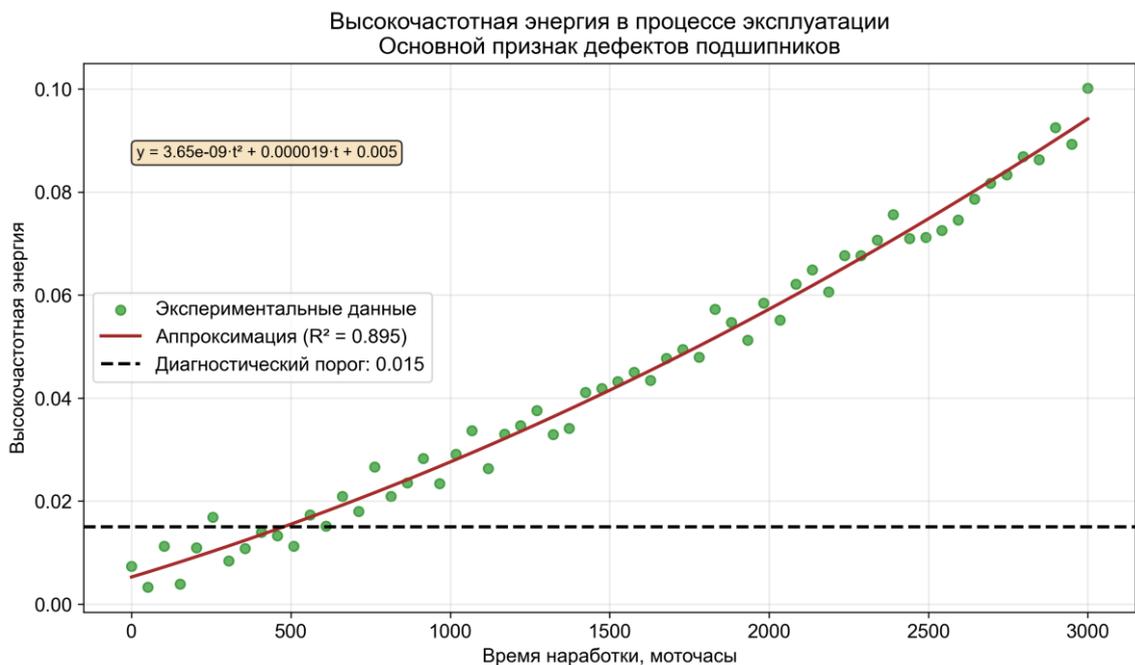


Рисунок 4.14 – Анализ высокочастотной составляющей вибросигнала

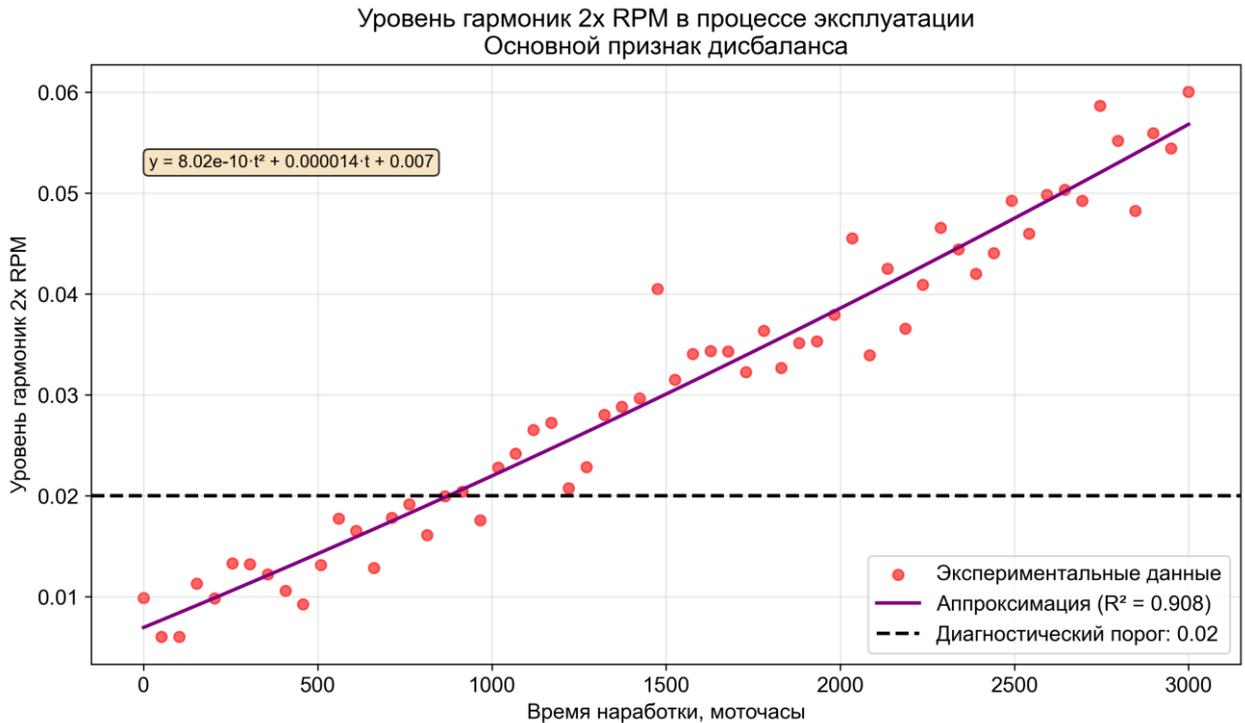


Рисунок 4.15 – Анализ коэффициента второй гармоники

Экссесс вибросигнала характеризует остроту пиков распределения амплитуд, коэффициент детерминации равен $R^2 = 0,89$ (Рисунок 4.16).

Этот параметр является индикатором ударных процессов, связанных с кавитацией и локальными дефектами. Несмотря на некоторую вариабельность, обусловленную влиянием внешних факторов, пороговое значение 0,3 позволяет выявлять развитие ударных процессов.

Помимо пяти проанализированных параметров, программный комплекс рассчитывает еще семь диагностических параметров, которые обеспечивают дополнительную информацию о состоянии гидравлического насоса. Асимметрия и дисперсия позволяют оценить распределение энергии вибросигнала и выявлять аномалии, связанные с неравномерным износом.

Энергетические характеристики, такие как сигнал/шум и коэффициент формы, оценивают общий уровень вибрации и обнаруживают фоновые шумы.

Интегральные показатели, коэффициент огибающей и индекс нестационарности используются для выявления модуляционных эффектов и нестационарных процессов в работе гидравлического насоса.

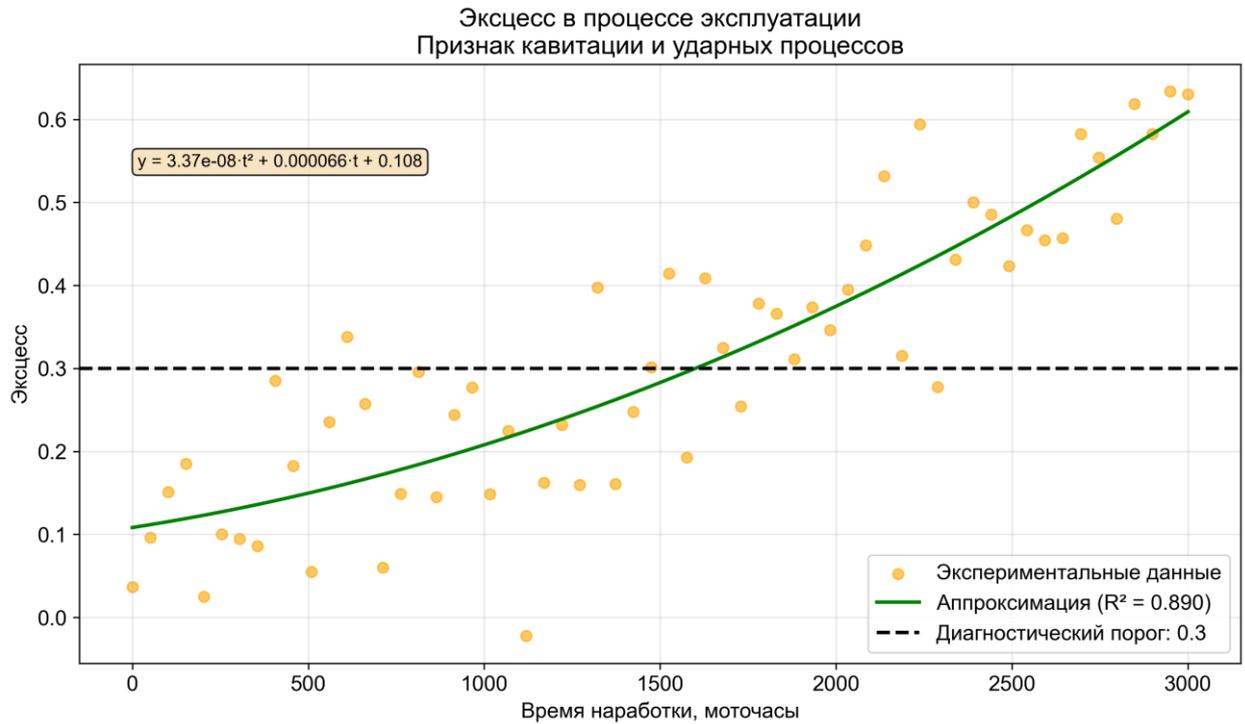


Рисунок 4.16 – Анализ эксцесса вибросигнала

Данные дополнительные параметры играют важную роль для диагностирования комбинированных дефектов, когда несколько видов повреждений развиваются одновременно. Комплексный анализ всех двенадцати диагностических параметров позволяет более точно определять техническое состояние шестеренного гидронасоса.

Для оценки связи диагностических признаков с результатами классификации выполнен статистический анализ экспериментальных данных. по каждому из четырёх технических состояний насоса НШ-32А.

Программный комплекс автоматически вычислял пять наиболее информативных параметров, отобранных на этапе параметрического анализа: среднеквадратичное значение, энергия боковых полос, высокочастотная энергия, эксцесс и уровень второй гармоники частоты вращения.

Диагностические пороги для этих параметров установлены на основе требований ГОСТ ISO 20816 и экспериментальных данных.

В таблицах 4,3–4,6 представлено распределение для каждого состояния по ключевым диагностическим признакам. Для верного диагностирования

указаны интервалы, соответствующие корректной работе насоса; для ошибочных – конкретные диапазоны значений, приведшие к неверной классификации. Такой подход позволил продемонстрировать, что подавляющее большинство измерений идентифицируются правильно, а все ошибки возникают исключительно при выходе контролируемых параметров за установленные пороги.

Таблица 4.3 – Распределение измерений для исправного состояния гидравлического насоса

СКЗ мм/с	E_{sb}	E_{HF}	К	Н	Количество измерений	Заключение программного комплекса
1,6-2,8	0,001- 0,005	0,002- 0,005	0,1-0,2	0,005- 0,01	49	Исправное (верно)
3,0-3,2	0,026- 0,03	0,004- 0,006	0,21- 0,24	0,011- 0,013	1	Износ зубьев (ошибка)

В 49 случаях (98 %) значения всех признаков находятся ниже установленных порогов, что обеспечивает распознавание исправного состояния. Единственное ошибочное измерение характеризуется повышением энергии боковых полос до 0,026–0,030 при СКЗ = 3,0–3,2 мм/с. Данное сочетание соответствует начальной стадии износа зубчатого зацепления, что и привело к ложному диагнозу.

Таблица 4.4 – Распределение измерений для состояния «Износ подшипника»

СКЗ мм/с	E_{sb}	E_{HF}	К	Н	Количество измерений	Заключение программного комплекса
3,5-4,8	0,003- 0,01	0,015- 0,028	0,30- 0,48	0,012- 0,022	45	Износ подшипника (верно)
4,5-5,0	0,008- 0,012	0,03- 0,036	0,50- 0,55	0,02- 0,024	5	Неверные диагнозы

В 45 случаях (90 %) диагностические признаки находятся в характерных для износа подшипников диапазонах: умеренный рост СКЗ (до 4,8 мм/с), повышенная высокочастотная энергия (0,015–0,028), эксцесс 0,30–0,48. Пять ошибочных измерений (10 %) имеют завышенные значения эксцесса ($>0,50$) и высокочастотной энергии ($>0,030$), что соответствует критериям комбинированного дефекта. Ошибка возникает не из-за сбоя алгоритма, а вследствие совпадения вибрационного портрета с другим классом повреждений.

Таблица 4.5 – Распределение измерений для состояния «Износ зубьев шестерен»

СКЗ мм/с	E_{sb}	E_{HF}	К	Н	Количество измерений	Заключение программного комплекса
3,2-4,5	0,025- 0,04	0,015- 0,028	0,25- 0,38	0,01- 0,018	46	Износ зубьев (верно)
4,2-4,6	0,008- 0,012	0,038- 0,045	0,42- 0,47	0,018- 0,021	4	Неверные диагнозы

В 46 случаях (92 %) правильно идентифицированы как износ зубьев. Четыре ошибочных диагноза (8 %) характеризуются одновременным превышением порогов по эксцессу ($>0,40$) и высокочастотной энергии ($>0,012$) при сохранении высокой энергии боковых полос. Данное сочетание признаков алгоритм интерпретирует как комбинированный дефект, что с физической точки зрения означает переход износа в более тяжёлую стадию с неисправностями подшипникового узла.

Таблица 4.6 – Распределение измерений для состояния «Комбинированный дефект»

СКЗ мм/с	E_{sb}	E_{HF}	К	Н	Количество измерений	Заключение программного комплекса
5,0– 6,2	0,035– 0,050	0,025– 0,038	0,48– 0,60	0,024– 0,032	44	Комбинированный дефект (верно)
4,8– 5,3	0,028– 0,033	0,022– 0,027	0,45– 0,50	0,022– 0,026	4	Износ зубьев (ошибка)
4,7– 5,1	0,020– 0,025	0,032– 0,037	0,52– 0,57	0,021– 0,025	2	Износ подшипника (ошибка)

Комбинированный дефект диагностируется в 44 случаях (88 %). Ошибки возникают при значениях признаков, близких к нижней границе области данного класса. В четырёх измерениях, ошибочно отнесённых к износу зубьев, энергия боковых полос составляет 0,028–0,033 (незначительно выше порога 0,025), а эксцесс и высокочастотная энергия ещё не достигают для комбинированного дефекта значений. В двух измерениях, классифицированных как износ подшипника, высокочастотная энергия равна 0,032–0,037 при относительно невысокой энергии боковых полос.

На основе анализа построена матрица неточностей (таблица 4.7), обобщающая результаты классификации.

Таблица 4.7 – Матрица неточностей классификации дефектов гидравлического насоса НШ-32А

Состояние	Исправное	Износ подшипника	Износ зубьев	Комбинированный дефект
Исправное	49	0	1	0
Износ подшипника	0	45	0	5
Износ зубьев	0	0	46	4
Комбинированный дефект	0	2	4	44

Точность диагностирования различных дефектов гидравлического насоса НШ-32А с использованием программного комплекса, основанном на комбинированном методе вибродиагностирования составляет:

- Для исправного состояния – 98%;
- Для износа подшипника – 90%;
- Для износа зубьев – 92%;
- Для комбинированного дефекта – 88%.

Наибольшая точность диагностирования достигнута для обнаружения износа зубьев шестерен (92 %), что связано с физической природой параметра «энергия боковых полос». Амплитудная модуляция вибрационного сигнала на частоте зацепления возникает при изменении геометрии контактирующих поверхностей зубьев и минимально чувствительна к другим типам дефектов, что делает данный признак высокоэффективным маркером именно износа зубчатого зацепления. Диагностирование комбинированных дефектов, требующее одновременного анализа нескольких параметров в условиях их взаимного влияния и частичного перекрытия диагностических областей показывает более низкую точность (88 %). Средняя точность диагностирования по четырем состояниям составляет 90,0 %, что

подтверждает работоспособность разработанного программного комплекса и его пригодность для практического применения при техническом обслуживании гидравлических насосов сельскохозяйственной техники.

4.5 Перспективы развития программы вибродиагностирования гидравлических насосов сельскохозяйственной техники

Программный комплекс реализует динамическую коррекцию пороговых значений вибраций по стандарту ГОСТ ISO 20816, учитывающую фактическую скорость вращения вала насоса. Однако в текущей версии программы не реализован механизм самообучения, но архитектура позволяет его внедрить в усовершенствованных версиях. Предполагаемая реализация будет основана на накоплении диагностической статистики и корректировке весовых коэффициентов комбинированного индекса дефектности:

$$D_i^{new} = 0,35 \times EPSD + 0,25 \times СКЗ + 0,20 \times K + 0,20 \times H_{ratio} + \Delta\omega; \quad (4.25)$$

где $\Delta\omega$ – корректирующая добавка, рассчитываемая методом наименьших квадратов на основе исторических данных.

Также перспективами развития программного комплекса является разработка и внедрение модуля прогнозирования остаточного ресурса на основе LSTM-сетей. Этот способ позволит достичь точности прогноза до 90%, при горизонте прогнозирования 100 моточасов.

Вторым направлением развития программного комплекса является создание цифровых двойников типовых гидравлических насосов. Виртуальные модели смогут воспроизводить вибрационные характеристики с учетом степени износа, температуры рабочей жидкости и давления в системе.

Выводы по четвертой главе

1. Разработан программный комплекс для автоматизированного вибродиагностирования гидравлических насосов на основе комбинированного анализа временных, частотных и статистических характеристик сигнала.

Архитектура включает три основных уровня: обработки сигналов, диагностический и интерфейсный, что обеспечило высокий уровень точности диагностирования гидравлических насосов.

2. Тестирование программы подтвердило эффективность алгоритмов предварительной обработки сигналов, фильтр Баттерворта 4-го порядка обеспечил подавление низкочастотных помех, а Z-score нормализация устранила влияние вариативности эксплуатационных условий. Применение метода Уэлча для расчета спектральной плотности мощности продемонстрировало устойчивость к шумам при идентификации гармоник вращения и частотных составляющих, указывающих на дефекты.

3. Проверка программного комплекса выполнена на вибрационных сигналах насоса НШ-32А при частотах вращения вала 1000, 1500 и 2000 об/мин для четырёх технических состояний (исправное, износ подшипников, износ зубьев шестерен, комбинированный дефект). Погрешность оценки диагностических параметров определялась сопоставлением с результатами измерений анализатором SpectraPro-4 и не превысила: СКЗ – 2,3 %, пик-фактор – 3,1 %, эксцесс – 3,5 %, энергия СПМ – 4,7 %, что соответствует требованиям ГОСТ ISO 20816. По результатам статистического анализа сформирована матрица неточностей, на основе которой рассчитана уточнённая точность классификации: исправное состояние – 98 %, износ подшипников – 90 %, износ зубьев шестерен – 92 %, комбинированный дефект – 88 %. Средняя точность диагностирования дефектов (по трём неисправным состояниям) составляет 90,0 %. Установлено, что ошибки классификации возникают при значениях диагностических признаков, близких к пороговым либо выходящих за пределы областей, характерных для данного класса, что подтверждает корректность работы программного комплекса.

4. Анализ точности разработанного программного комплекса для автоматизированного вибродиагностирования гидравлических насосов, проведённый на экспериментальных данных, показал, что средняя точность диагностирования дефектов гидравлических насосов составляет 90,0 %.

Наибольший результат достигнут для износа зубьев шестерен (92 %), поскольку параметр «энергия боковых полос» непосредственно отражает состояние зубчатого зацепления и минимально чувствителен к другим видам повреждений. Информативность диагностических признаков подтверждена регрессионным анализом: аппроксимация их временной динамики квадратичными зависимостями методом наименьших квадратов дала значения коэффициента детерминации $R^2 = 0,89-0,92$, что свидетельствует о связи признаков с развитием повреждений. Для основных контролируемых параметров установлены диагностические пороги в соответствии с ГОСТ ISO 20816: среднеквадратичное значение вибрации – 2,8 мм/с (граница нормы для машин класса II), энергия боковых полос – 0,025, высокочастотная энергия – 0,015, уровень второй гармоники – 0,020, эксцесс – 0,3. Данные пороги определены на основе статистического анализа выборок исправных и дефектных насосов, проверены в ходе испытаний и соответствуют требованиям стандарта.

ГЛАВА 5. ЭКОНОМИЧЕСКОЕ ОБОСНОВАНИЕ ВНЕДРЕНИЯ РАЗРАБОТАННОГО КОМБИНИРОВАННОГО МЕТОДА ВИБРОДИАГНОСТИРОВАНИЯ ГИДРАВЛИЧЕСКИХ НАСОСОВ СЕЛЬСКОХОЗЯЙСТВЕННОЙ ТЕХНИКИ

Эксплуатация гидравлических систем сельскохозяйственной техники агропромышленного комплекса сопровождается повышенной интенсивностью и сложными условиями, включающими повышенные ударные и вибрационные нагрузки, запыленность, сезонные изменения температур, влажности и интенсивности работ. Все это приводит к ускоренному износу и возникновению внезапных отказов элементов гидравлической системы сельскохозяйственной техники, особенно в сезоны посева и уборки (рисунок 5.1.)

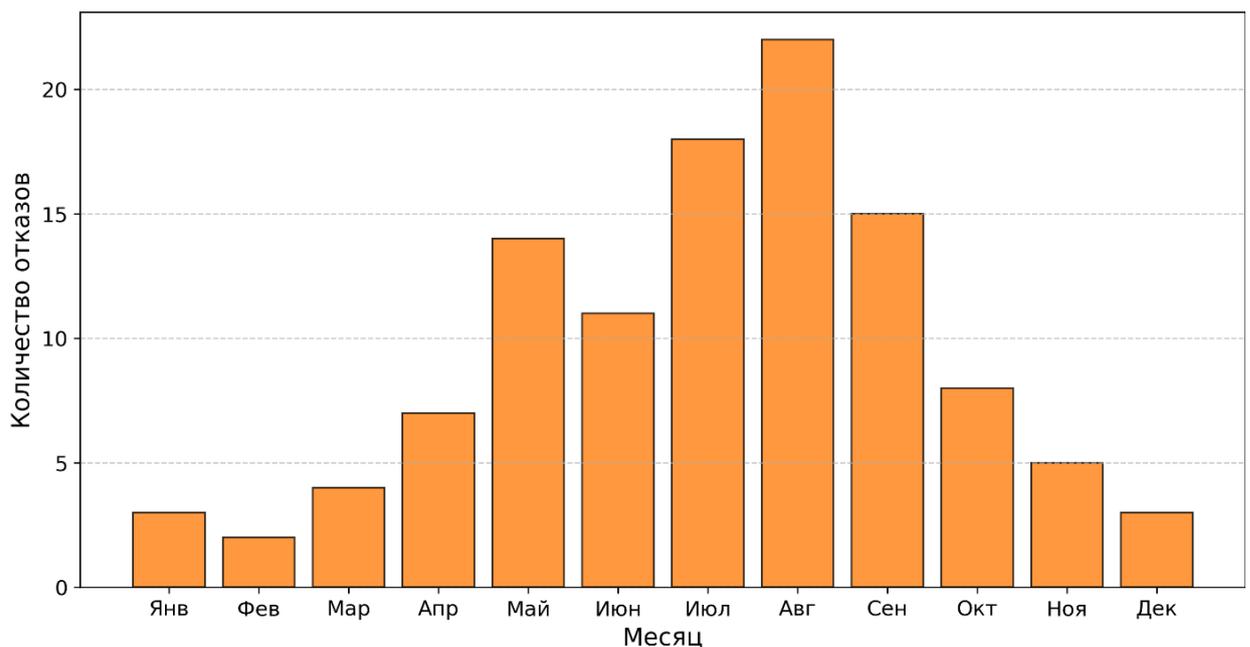


Рисунок 5.1 – Сезонность отказов гидравлической системы
сельскохозяйственной технике

Анализ особенностей эксплуатации разномарочной сельскохозяйственной техники в последнее время обосновывает целесообразность перехода от системы ППР к научно-обоснованной системе технического обслуживания ремонта по фактическому состоянию машин и

оборудования. Сравнение стратегий систем планово-предупредительного ТОиР и ТО и Р по фактическому состоянию машин и оборудования представлены на рисунке 5.2.

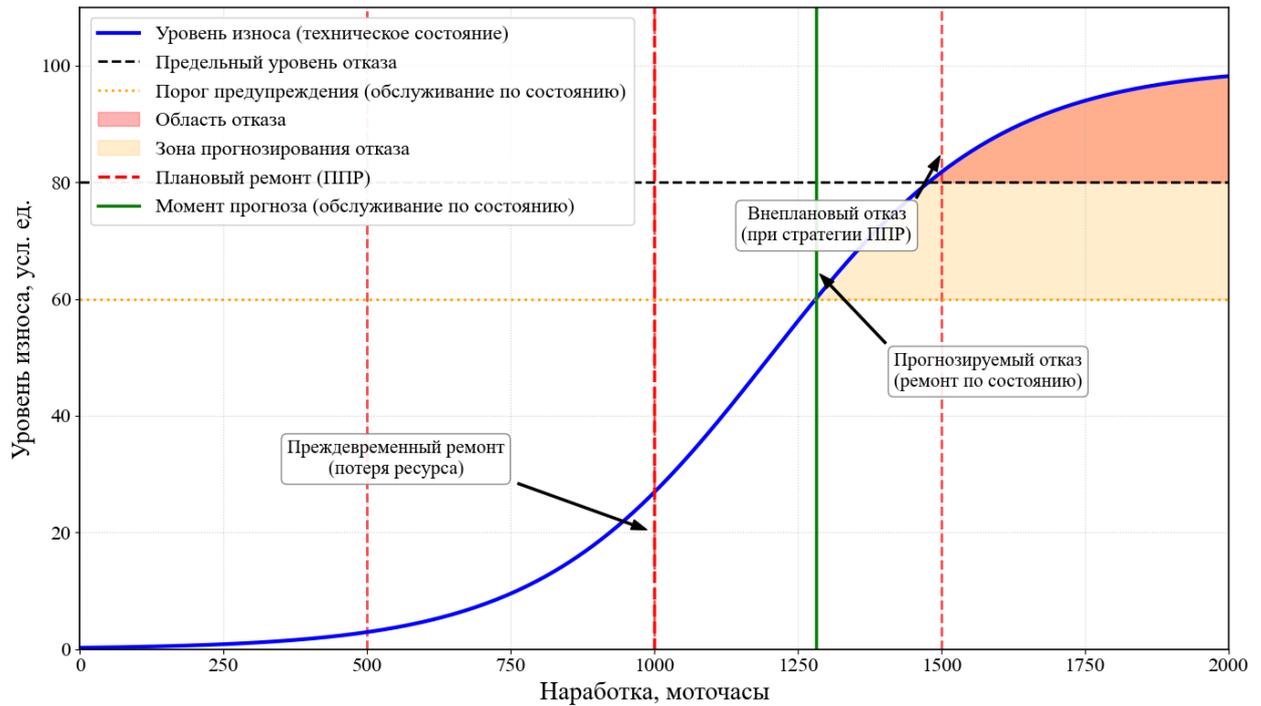


Рисунок 5.2 – Сравнение стратегий систем ППР и обслуживания по фактическому состоянию.

Разработанный в диссертационном исследовании комбинированный метод вибродиагностирования гидравлических насосов сельскохозяйственной технике и программный комплекс представляет собой инструментарий для реализации системы технического обслуживания и ремонта технике по фактическому состоянию. Его применение позволяет обнаруживать дефекты на ранней стадии развития и планировать ремонтные работы, тем самым минимизировать затраты средств и времени.

Переход от системы ППР к системе обслуживания по состоянию с использованием разработанного программного комплекса изменяет экономическую модель эксплуатации гидравлической системы трактора. Ключевым является не просто сокращение затрат на ремонт, а оптимизация жизненного цикла узла. Экономический эффект внедрения комбинированного

метода складывается от затрат ремонт или замену гидравлического насоса и уменьшение ущерба от простоя техники.

Экономический эффект от внедрения разработанного комбинированного метода вибродиагностирования гидравлических насосов в СПК «Стрелецкий» Тульской области на один трактор типа МТЗ-82 с наработкой 1500 мото-часов составил 237,9 тыс. рублей, за счет сокращения затрат на ремонт гидравлических насосов (27,9 тыс. руб.) и уменьшения времени на ожидание устранения последствий отказов гидравлических насосов на 60 часов (210 тыс. руб.). При этом, сокращение времени на устранение последствий отказов гидравлического насоса составило 15...45 %, а затраты на их устранение стали меньше на 30...70 %.

Вывод по пятой главе

Внедрение результатов исследования в СПК «Стрелецкий» Тульской области подтвердило эффективность разработанного комбинированного метода вибродиагностирования гидравлических насосов сельскохозяйственной техники, при этом время на устранение последствий отказов гидравлических насосов сократилось на 15...45%, а потери на ожидание их устранения на 30...70%. Годовой экономический эффект от внедрения разработанного комбинированного метода вибродиагностирования гидравлических насосов на один трактор типа МТЗ-82 с наработкой 1500 мото-часов составил 237,9 тыс. рублей, за счет сокращения затрат на ремонт гидравлических насосов (27.9 тыс. руб.) и уменьшения времени на ожидание устранения последствий отказов гидравлических насосов около 60 часов (210 тыс. рублей).

ЗАКЛЮЧЕНИЕ

1. Проведен комплексный анализ, систематизация и критическая оценка современных методов вибродиагностирования технических систем. Для условий нестационарных режимов и наличия шумов обоснован и предложен к применению следующий комплекс методов и признаков: для обработки сигналов – анализ спектральной плотности мощности (СПМ); для извлечения признаков – набор статистических (среднеквадратичное значение, пик-фактор, эксцесс, асимметрия, импульсный фактор) и энергетических параметров (общая энергия, энергия в гармонических и боковых полосах, высокочастотная энергия, комбинированный индекс дефектности); для классификации – подход на основе пороговых значений, скорректированных под скорость вращения и тип оборудования.

2. Разработан адаптивный алгоритм вибродиагностирования гидравлических насосов сельскохозяйственной техники, который комбинирует анализ сигнала во временной и частотной областях, интеллектуально отбирает ключевые диагностические признаки вибросигнала, классифицирует состояние гидравлического насоса по стандарту ГОСТ ISO 20816 и детализирует дефекты гидравлических насосов по спектральным параметрам.

3. Проведенное тестирование в УНПЦ садоводства и овощеводства имени В.И. Эдельштейна ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева разработанного комбинированного метода вибродиагностирования для оценки технического состояния гидравлических насосов, на примере насоса НШ-32А трактора МТЗ-82.1 с использованием пьезоэлектрического акселерометра Metrix SA6200A и анализатора вибросигналов X-Viber подтвердило его адекватность в зависимости от разных состояний тестируемого гидравлического насоса.

4. Разработан программный комплекс для автоматизированного метода вибродиагностирования гидравлических насосов на основе

комбинированного анализа временных, частотных и статистических характеристик сигнала. Погрешность оценки диагностических параметров определялась сопоставлением с результатами измерений анализатором SpectraPro-4 и не превысила: СКЗ – 2,3%, пик-фактор – 3,1%, эксцесс – 3,5%, энергия СПМ – 4,7%, что соответствует требованиям ГОСТ ISO 20816.

5. Анализ точности диагностирования разработанного программного комплекса подтвердил его эффективность при обнаружении дефектов гидравлических насосов. На основе статистического анализа достигнута точность классификации: исправное состояние – 98%, износ зубьев шестерен – 92%, износ подшипников – 90%, комбинированные дефекты – 88%. Средняя точность диагностирования дефектов составляет 90,0 %. Разработанный комплекс рекомендован к использованию при диагностировании гидравлических систем сельскохозяйственной техники, при проведении технического обслуживания ТО-1 тракторов, на предприятиях технического сервиса машин и оборудования АПК России.

6. Внедрение результатов исследования в СПК «Стрелецкий» Тульской области подтвердило эффективность разработанного комбинированного метода вибродиагностирования гидравлических насосов сельскохозяйственной техники, при этом время на устранение последствий отказов гидравлических насосов сократилось на 15...45%, а потери на ожидание их устранения на 30...70%. Годовой экономический эффект от внедрения разработанного комбинированного метода вибродиагностирования гидравлических насосов на один трактор типа МТЗ-82 с наработкой 1500 мото-часов составил 237,9 тыс. рублей, за счет сокращения затрат на ремонт гидравлических насосов (27.9 тыс. руб.) и уменьшения времени на ожидание устранения последствий отказов гидравлических насосов около 60 часов (210 тыс. рублей).

Рекомендации и перспективы дальнейшей разработки темы

Рекомендуется использование разработанного комбинированного метода вибродиагностирования и программного комплекса при эксплуатации гидравлических систем сельскохозяйственной техники на предприятиях АПК. Результаты работы могут использоваться в учебных материалах для подготовки специалистов по направлениям 35.03.06 «Агроинженерия», 23.03.03 «Эксплуатация транспортно-технологических машин и комплексов» и 23.05.01 «Наземные транспортно-технологические средства» в образовательных учреждениях Российской Федерации.

Перспективы дальнейших исследований связаны с развитием разработанного комбинированного метода вибродиагностирования гидравлических насосов, включая: создания алгоритмов прогнозирования остаточного ресурса на основе анализа временных рядов диагностических параметров; адаптацию метода для других типов гидравлического оборудования; создание программного обеспечения с расширенными возможностями сбора и анализа данных.

СПИСОК ЛИТЕРАТУРЫ

1. Модель обеспеченности ремонтно-технических воздействий при эксплуатации машин / М. М. Махмутов, К. В. Кулаков, Ю. Р. Хисматуллина, К. Л. Алексеев // Экономика, труд, управление в сельском хозяйстве. – 2023. – № 4(98). – С. 135-139. – DOI 10.33938/234-135.
2. Совершенствование средств диагностирования как фактор повышения ресурсосбережения при эксплуатации сельскохозяйственной техники / М. Н. Костомахин, А. С. Саяпин, Е. В. Пестряков, Н. А. Петрищев // Конструирование, использование и надежность машин сельскохозяйственного назначения. – 2023. – № 1(22). – С. 103-111.
3. Совершенствование системы технического обслуживания и ремонта машин и оборудования в АПК / Н. В. Никитин, А. В. Котин, А. М. Кузьмин, В. Н. Сивцов // Сельский механизатор. – 2025. – № 7. – С. 3-5. – DOI 10.47336/0131-7393-2025-7-3-4-5-25.
4. Блувбанд З. и др. Современные концепции прогнозирования неисправностей двигателей: проблемы и решения // Двигатели. – 2013. – №2 (86). – С. 23–27.
5. Нгуен, Ч. М. Имитационная модель диагностирования насосов транспортных средств / Ч. М. Нгуен, В. А. Зорин // Высокие технологии в строительном комплексе. – 2023. – № 2. – С. 64-69.
6. Повышение уровня технического обслуживания энергонасыщенной техники / Ю. В. Катаев, М. Н. Костомахин, Н. А. Петрищев [и др.] // Техника и оборудование для села. – 2022. – № 4(298). – С. 27-31. – DOI 10.33267/2072-9642-2022-4-27-31.
7. Peng Y., et al. Current status of machine prognostics in condition-based maintenance: a review. // International Journal of Advanced Manufacturing Technology. – 2010. – Vol. 50. – P. 297–313.
8. Нгуен, Ч. М. Повышение надёжности гидравлических систем строительных машин методами технического диагностирования :

специальность 05.05.04 "Дорожные, строительные и подъемно-транспортные машины" : диссертация на соискание ученой степени кандидата технических наук / Нгуен Чонг Минь, 2022. – 145 с.

9. Ступин, О. А. Вибрационный метод диагностики, как современный способ неразрушающего контроля и выявления неисправностей технологических машин и оборудования / О. А. Ступин // Чтения академика В. Н. Болтинского, Москва, 25–26 января 2022 года. Том Часть 2. – Москва: ООО «Сам полиграфист», 2022. – С. 103-109.

10. Ступин, О. А. Вибродиагностика как современный метод контроля и диагностирования гидроприводов технологических машин / О. А. Ступин, С. И. Некрасов, Р. Г. Кучинский // Международный технико-экономический журнал. – 2022. – № 5-6. – С. 75-86. – DOI 10.34286/1995-4646-2022-86-5/6-76-87.

11. ГОСТ ИСО 10816–1–97 Вибрация. Контроль состояния машин по результатам измерений вибрации на невращающихся частях. Часть 1. Общие требования.

12. Балицкий Ф.Я. Современные методы вибрационной диагностики машин и конструкций. – М.: МЦНТИ, 2015.

13. Ширман А., Соловьев А. Практическая вибродиагностика и мониторинг состояния механического оборудования. – М.: Спектр–инженеринг, 1996.

14. Devendiran S., Manivannan K. Vibration Based Condition Monitoring and Fault Diagnosis Technologies For Bearing and Gear Components–A Review // International Journal of Applied Engineering Research. – 2016. – Vol. 11, №6. – P. 3966–3975.

15. ГОСТ Р ИСО 13374–1–2011. Контроль состояния и диагностика машин. Обработка, передача и представление данных. Часть 1. Общее руководство.

16. ГОСТ Р ИСО 13374–2–2011 Контроль состояния и диагностика машин. Обработка, передача и представление данных. Часть 2. Обработка данных.
17. ГОСТ Р ИСО 13373–2–2009 Контроль состояния и диагностика машин. Вибрационный контроль состояния машин. Часть 2. Обработка, анализ и представление результатов измерений вибрации.
18. Ступин, О. А. Проблема обработки сигналов при использовании вибрационного метода диагностики элементов гидросистем строительных и дорожных машин во время их эксплуатации / О. А. Ступин, А. С. Апатенко, С. И. Некрасов // Транспортные и транспортно-технологические системы : Материалы Международной научно-технической конференции, Тюмень, 13–14 апреля 2023 года / Отв. редактор П.В. Евтин. – Тюмень: Тюменский индустриальный университет, 2023. – С. 194-198.
19. Zheng H. et al. Gear fault diagnosis based on continuous wavelet transform //Mechanical Systems and Signal Processing. – 2002. – Vol. 16(2–3). – P. 447–457.
20. Li Z., et al. Virtual prototype and experimental research gear multi-fault diagnosis using wavelet–autoregressive model and principal component analysis method //Mechanical Systems and Signal Processing. – 2011. – Vol. 25(7). – P. 2589–2607.
21. Saravanan N., Ramachandran K. I. Fault diagnosis of spur bevel gear box using discrete wavelet features and Decision Tree classification //Expert Systems with Applications. – 2009. – Vol. 36(5). – P. 9564–9573.
22. Lei Y., et al. A multidimensional hybrid intelligent method for gear fault diagnosis //Expert Systems with Applications. – 2010. – Vol. 37(2). – P. 1419–1430.
23. Unal M., et al. Fault diagnosis of rolling bearings using a genetic algorithm optimized neural network //Measurement. – 2014. – Vol. 58. – P. 187–196.

24. Gullulu S., Seker S. Signal based approach for data mining in fault detection of induction motor // *Scientific Research and Essays*. – 7 October, 2011. – Vol. 6(22). – P. 4720–4731.
25. Information Bank of Parametric Data for Controlling the Resource Loading of Elements of Technical Systems of Technological Machines / A. S. Apatenko, N. S. Sevryugina, A. V. Mironov, O. A. Stupin // *Steel in Translation*. – 2023. – Vol. 53, No. 3. – P. 238-242. – DOI 10.3103/s0967091223030026.
26. Tandon N. A comparison of some vibration parameters for condition monitoring of rolling element bearings. // *Measurement*. – 1994 – Vol. 12. – P. 285–286.
27. Jardine A.K.S., et al. A review on machinery diagnostics and prognostics implementing condition-based maintenance. // *Mechanical Systems and Signal Processing*. – 2006. – Vol. 20. – P. 1483–1510.
28. Dalpiaz G., et al. Effectiveness and sensitivity of vibration processing techniques for local fault detection in gears. // *Mechanical System and Signal Processing*. – 2000. – Vol. 14. – P. 387–412.
29. Baillie D. C., Mathew J. A comparison of autoregressive modeling techniques for fault diagnosis of roller element bearings // *Mechanical Systems and Signal Processing*. – 1996. – Vol. 10. – P. 1–17
30. Garibaldi L., et al. Diagnosis of rolling elements bearing based on inverse autoregressive filter. // *Key Engineering Materials*. – 2009. – Vol. 413–414. – P. 635–642.
31. Sawalhi R.B., et al. The enhancement of fault detection and diagnosis in rolling element bearings using minimum entropy disconsolation combined with spectral kurtosis. // *Mechanical System and Signal Processing*. – 2007. – Vol. 21. – P. 2616–2633.
32. Tandon N., Choudhury A. A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings. // *Tribology International*. – 1999. – Vol. 32. – P. 469–480.

33. Devendiran S., et al. An Early Bearing Fault Diagnosis using Effective Feature Selection Methods and Data Mining Techniques // International Journal of Engineering and Technology (IJET). – Apr–May 2015. – Vol. 7, №2. – P. 583–598.
34. Cooley J.W., Tukey J.W.. An algorithm for the machine calculation of complex fourier series //Mathematics of Computation. – 1965. – Vol. 19. – P. 297–301.
35. Randall R.B. Signal decomposition for symptom enhancement: A journey from fourier analysis through time/frequency analysis to blind source separation. /In: Keynote lecture at ISMA, Leuven, 2017.
36. Ступин, О. А. Анализ методов обработки вибросигналов при диагностировании элементов гидросистем технологических машин / О. А. Ступин, С. И. Некрасов // Инновации в природообустройстве и защите в чрезвычайных ситуациях: Материалы IX Международной научно-практической конференции, Саратов, 27–28 апреля 2022 года. – Саратов: Общество с ограниченной ответственностью "Амирит", 2022. – С. 371-374.
37. Saravanan N., Ramachandran K.I. Fault diagnosis of spur bevel gear box using discrete wavelet features and Decision Tree classification // Expert Systems with Applications, – 2009. – Vol.36(5): P. 9564–9573.
38. Liu T. I., et al. Detection of Roller bearing defects using expert system and fuzzy logic //Mechanical Systems and Signal Processing. – 1996. –Vol. 10. – P. 595–614.
39. Sugumaran V., Ramachandran K. I. Automatic rule learning using decision tree for fuzzy classifier in fault diagnosis of roller bearing //Mechanical Systems and Signal Processing. – 2007. – Vol. 21. – P. 2237–2247.
40. Nguyen Ngoc–Tu, et al. Optimal feature selection using genetic algorithm for mechanical fault detection of induction motor //Journal of Mechanical Science and Technology. – 2008. – Vol. 22. – P. 490–496.
41. Bishop C.M. Pattern Recognition and Machine Learning – (Information Science and Statistics), 2006.

42. Ding S., et al. On the Application of PCA Technique to Fault Diagnosis // Tsinghua Science And Technology. – 2010. – Vol.15, №2. – P. 138–144.
43. Villez K., et al. Combining multiway principal component analysis (MPCA) and clustering for efficient data mining of historical data sets of SBR processes // Water Science & Technology. – 2008. – WST | 57.10 |. – P. 1659–1666.
44. Wang S., Xiao Fu. Detection and diagnosis of AHU sensor faults using principal component analysis method // Energy Conversion and Management. – 2004. – Vol. 45. – P. 2667–2686.
45. Deng X., et al. Modified kernel principal component analysis based on local structure analysis and its application to nonlinear process fault diagnosis // Chemometrics and Intelligent Laboratory Systems. – 2013. – Vol. 127. – P. 195–209.
46. Dhakar A., Singh B., Gupta P. Fault diagnosis of air compressor set-up using decision tree based J48 classification algorithm // Journal of Engineering Research. – 2024. – Vol. 12, No. 4. – P. 1011–1025.
47. Sugumaran V., Muralidharan V., Ramachandran K.I. Feature selection using Decision Tree and classification through Proximal Support Vector Machine for fault diagnostics of roller bearing // Mechanical Systems and Signal Processing. – 2007. – Vol. 21, No. 2. – P. 930–942.
48. Malhi A., Gao R.X. PCA-based feature selection scheme for machine defect classification // IEEE Transactions on Instrumentation and Measurement. – 2004. – Vol. 53, No. 6. – P. 1517–1525.
49. Peng H., Long F., Ding C. Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2005. – Vol. 27, No. 8. – P. 1226–1238.
50. Голубев, И. Г. Перспективные направления цифровизации инженерной сферы АПК / И. Г. Голубев, А. С. Апатенко, Н. С. Севрюгина // Перспективные направления рационального землепользования и цифровизация земледелия : Сборник докладов VII Международной научно-

практической конференции, посвященной 300-летию Российской академии наук, Курск, 02–04 октября 2023 года. – Курск: Федеральное государственное бюджетное научное учреждение "Курский федеральный аграрный научный центр", 2023. – С. 54-57.

51. Chandola V., et al. Anomaly detection : A survey. // ACM Computing Surveys. – 2019. – Vol. 41, №3. – P. 1– 58.

52. Hawkins, D. M.: Identification of Outliers. – London – New York: Chapman and Hall, 1980.

53. Tan P.-N., et al. Introduction to Data Mining. – Reading: Addison–Wesley, 2005.

54. Isermann R. Model–based fault–detection and diagnosis – status and applications // Annual Reviews in Control. – 2005. – Vol. 29, №1. – P. 71–85.

55. Isermann R. Fault–diagnosis systems: An introduction from fault detection to fault tolerance. – Berlin: Springer–Verlag, 2006.

56. Venkatasubramanian V. et al. A review of process fault detection and diagnosis Part I: Quantitative model–based methods // Computers and Chemical Engineering. – 2003. – №27. Issue 3. – P. 293–311.

57. Kohonen T. Self–Organizing Maps. – Springer, 1997.

58. Вероятностный анализ показателей надежности насосов с помощью нейронной сети / Я. А. Тынченко, В. В. Кукарцев, К. А. Башмур [и др.] // Горный информационно-аналитический бюллетень (научно-технический журнал). – 2024. – № 7-1. – С. 126-136. – DOI 10.25018/0236_1493_2024_71_0_126.

59. Применение нейронной сети в управлении техническим состоянием сельскохозяйственной техники / А. С. Дорохов, Ю. В. Катаев, Е. В. Пестряков [и др.] // Вестник машиностроения. – 2025. – Т. 104, № 8. – С. 663-667. – DOI 10.36652/0042-4633-2025-104-8-663-667.

60. Willsky A. S. A Survey of Design Methods for Failure Detection in Dynamic Systems // Automatica. – 1976. – Vol. 12. – P. 601–611.

61. Frank P. M. Fault Diagnosis in Dynamic Systems Using Analytical and Knowledge-based Redundancy. – A Survey and Some New Results // *Automatica*. – 1990. – Vol. 26, №3. – P. 459–474.
62. Schwarte A., Isermann R. Neural Network Applications for Model Based Fault Detection with Parity Equations / In: Camacho E.F., Basañez L., de la Puente J.A. (eds.) *Proceedings of the 15th IFAC World Congress, Barcelona, Spain, 21–26 July 2002*. – Oxford: Elsevier, 2003. – Vol. 36, Issue 5. – P. 205–210.
63. Fuente M.J., Represa C. A comparative study of neural networks based approach for fault detection / In: Patton R.J., Chen J. (eds.): *Fault Detection, Supervision and Safety for Technical Processes 1997*, Vols. 1–3. – Oxford: Elsevier, 1998. – P. 471–476. ISBN: 0-08-042381-7.
64. Azar A.T. (ed.) *Fuzzy Systems*. – Rijeka, Croatia: IntechOpen, 2010. – 228 p. – ISBN: 978-953-7619-92-3.
65. Kulkarni M. Fault Detection in Hydraulic System Using Fuzzy Logic / *Proceedings of the World Congress on Engineering and Computer Science 2009*. – WCECS 2009. – Vol. II. – Oct.2009.
66. Venkatasubramanian V., Rengaswamy R., Kavuri S.N. A review of process fault detection and diagnosis Part II: Qualitative models and search strategies // *Computers and Chemical Engineering*. – 2003. – Vol. 27, Issue 3. – P. 313–326. DOI: 10.1016/S0098-1354(02)00161-8.
67. Alpaydin E. *Introduction to machine learning*. – Cambridge MA: The MIT Press, 2004.
68. Azevedo H., et al. A review of wind turbine bearing condition monitoring: state of the art and challenges // *Renewable & Sustainable Energy Reviews*. – 2016. – Vol. 56(4). – P. 368–379.
69. Zhu H., et al. Shift invariant sparse coding for blind source separation of single channel mechanical signal // *Journal of Vibration Engineering*. – 2015. – Vol. 28(4). – P. 625–632.
70. Hu G. S. *Modern signal processing course*. – Beijing: Tsinghua University Press, 2004.

71. Zhang M. J., et al. EEMD method and its application in mechanical fault diagnosis. – Beijing: National Defense Industry Press, 2015.
72. Czajkowski A., Patan K. Robust fault detection by means of echo state neural network // *Advances in Intelligent Systems and Computing*. – 2016. – Vol. 386. – P. 341–352.
73. Malik H., Mishra S. Application of probabilistic neural network in fault diagnosis of wind turbine using FAST, TurbSim and Simulink // *Procedia Computer Science*. – 2015. – 58. – P. 186–193.
74. Chen Y., et al. Application of fault tree analysis and fuzzy neural networks to fault diagnosis in the Internet of Things (IoT) for aquaculture // *Sensors*. – 2017. – 17(1). – P. 153.
75. Zhang D., Wang T., Zhu X. Overview of Sample Reduction Algorithms for Support Vector Machine // *Jisuanji kexue*. – 2024. – Vol. 51, No. 7. – P. 59–70. DOI: 10.11896/jsjcx.230400143.
76. Liang N., Yuan Z., Kang J., Jiang R., Zhang J., Yu X. A multi-output fault diagnosis framework for hydraulic system using a CNN-SVM hierarchical learning strategy // *Measurement Science and Technology*. – 2024. – Vol. 35, No. 7. – 076212. DOI: 10.1088/1361-6501/ad3f3b.
77. Liu Y., Gu H., Qin P. A verified training support vector machine in bearing fault diagnosis // *Measurement Science and Technology*. – 2024. – Vol. 35, No. 11. – ad6c75. DOI: 10.1088/1361-6501/ad6c75.
78. Enrique Sucar L., et al. Multi-label classification with Bayesian network-based chain classifiers // *Pattern Recognition Letters*. – 2014. – Vol. 41(1). – P. 14–22.
79. Goharrizi A.Y., Sepehri N., Wu Y. A wavelet-based approach for diagnosis of internal leakage in hydraulic actuators using on-line measurements // *International Journal of Fluid Power*. – 2010. – Vol. 11, No. 1. – P. 61–69. DOI: 10.1080/14399776.2010.10780998.
80. Saeed R.A., Galybin A.N., Popov V. 3D fluid-structure modelling and vibration analysis for fault diagnosis of Francis turbine using multiple ANN and

multiple ANFIS // *Mechanical Systems and Signal Processing*. – 2013. – Vol. 34, No. 1–2. – P. 259–276. DOI: 10.1016/j.ymssp.2012.08.005.

81. Lu C., Wang S., Zhang C. Fault diagnosis of hydraulic piston pumps based on a two-step EMD method and fuzzy C-means clustering // *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*. – 2016. – Vol. 230, No. 16. – P. 2913–2928. DOI: 10.1177/0954406215602285.

82. Chai K., Zhang M.J., Huang J., Wang Z.Y. Fault diagnosis of hydraulic system based on time-frequency characteristics and PCA-KELM // *Journal of PLA University of Science and Technology (Natural Science Edition)*. – 2015. – No. 4. – P. 394–400.

83. Ступин, О. А. Методика вибрационной диагностики гидравлической системы технологических машин при выполнении сельскохозяйственных работ на примере шестеренного насоса НШ-32А / О. А. Ступин, А. В. Шитикова, А. С. Апатенко // *Агроинженерия*. – 2025. – Т. 27, № 6. – С. 35-44. – DOI 10.26897/2687-1149-2025-6-35-44.

84. Xu L., Yu X., Hou Z. Analysis of the Causes of Driving Gear Shaft Fractures in Gear Pumps // *J. Fail. Anal. Prev.* – 2020. – Vol. 20. – P. 242–248.

85. Qin X., et al. Fracture failure analysis of transmission gear shaft in a bidirectional gear pump. // *Engineering Fail. Anal.* – 2020. – Vol. 118. – P. 173–182.

86. Yordanov B., et al. Exploitation Fatigue Fraction of Hydraulic Pump Shaft // *International Journal NDT Days*. – 2019, II. – P. 554–561.

87. Scott Pflumm, J., Banks J.C. Utilizing dynamic fuel pressure sensor for detecting bearing Spalling and gear pump failure modes in Cummins pressure time (PT) Pumps // *Annu. Conf. Progn. Health Manag. Soc.* – 2011. – Vol. 3. – P. 490–501.

88. Wang Y., Wang Y. Fracture Failure Analysis of Flameproof Enclosure of Hydraulic Pump Regulator. – *IOP Conf. Ser. Mater. Science Engineering 2020*, 768,

89. Yu H., Li H., Li Y. Vibration signal fusion using improved empirical wavelet transform and variance contribution rate for weak fault detection of hydraulic pumps // *ISA Transactions*. – 2020. – Vol. 107. – P. 385–401. DOI: 10.1016/j.isatra.2020.07.025.
90. Li Z., Jiang W., Zhang S., Sun Y., Zhang S. A Hydraulic Pump Fault Diagnosis Method Based on the Modified Ensemble Empirical Mode Decomposition and Wavelet Kernel Extreme Learning Machine Methods // *Sensors*. – 2021. – Vol. 21, No. 8. – 2599. DOI: 10.3390/s21082599.
91. Jia M.X., Wang F.L., Zhao Z. A novel approach for hydraulic pump fault diagnosis based on adaptive empirical mode decomposition and Teager energy operator // *Mechanical Systems and Signal Processing*. – 2013. – Vol. 36, No. 2. – P. 487–504. DOI: 10.1016/j.ymssp.2012.10.010.
92. Gao S.X., Chen X.H., Ding Y. Fault recognition of gear pump based on EMD neural network // *Appl. Mechanical Mater.* – 2013. – P. 333–335, 1635–1639.
93. Tian Z., Zhang M., Li Z., Zhao J., Zhang K. Degradation feature extraction of the hydraulic pump based on local characteristic-scale decomposition and multi-fractal spectrum // *Advances in Mechanical Engineering*. – 2016. – Vol. 8, No. 3. – 1687814016640242 (12 pp.). DOI: 10.1177/1687814016640242.
94. Ding Y., et al. An EWT–PCA and extreme learning machine based diagnosis approach for hydraulic pump // *IFAC Pap.* – 2020. – Vol. 53. – P. 43–47.
95. Lan Y., et al. Fault diagnosis on slipper abrasion of axial piston pump based on Extreme Learning Machine // *Meas. J. Int. Meas. Confed.* – 2018. – Vol. 124. – P. 378–385.
96. Wu S., et al. Kernel principal component analysis fault diagnosis method based on sound signal processing and its application in hydraulic pump // *In Proceedings of the 2011 International Conference on Fluid Power and Mechatronics, Beijing, China, 17–20 August 2011; Vol. 1.* – P. 98–101.
97. Jiang W., et al. Study on a fault identification method of the hydraulic pump based on a combination of voiceprint characteristics and extreme learning machine // *Processes*. – 2019. – Vol. 7. – P. 894 – 903.

98. Tang S., Zhu Y., Yuan S. An adaptive deep learning model towards fault diagnosis of hydraulic piston pump using pressure signal // *Engineering Failure Analysis*. – 2022. – Vol. 138. – 106300. DOI: 10.1016/j.engfailanal.2022.106300.
99. Wang Y., Zhao S., Zhou J., Lv G., Wang S. A practical signal processing approach for fault detection of axial piston pumps using instantaneous angular speed // *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*. – 2021. – Vol. 235, No. 20. – P. 4788–4799. DOI: 10.1177/0954406220917704.
100. Liu J.M., et al. Hydraulic pump fault diagnosis based on chaotic characteristics of speed signals under non-stationary conditions // *Proc. Inst. Mechanical Engineering Part C J. Mechanical Engineering Science* – 2021. – Vol. 235. – P. 3468–3482.
101. Buiges C.G., König C. A Sensor Data-Based Approach for the Definition of Condition Taxonomies for a Hydraulic Pump // *Engineering Proc.* – 2020. – Vol. 2, 82.
102. Przystupa K., et al. Diagnostics of Transient States in Hydraulic Pump System with Short Time Fourier Transform // *Adv. Science Technol. Res. J.* – 2020. – Vol. 14. – P. 178–183.
103. Ma Z., et al. Engineering-driven performance degradation analysis of hydraulic piston pump based on the inverse Gaussian process // *Qual. Reliab. Engineering Int.* – 2019. – Vol. 35. – P. 2278–2296.
104. Tang S., Zhu Y., Yuan S. An improved convolutional neural network with an adaptable learning rate towards multi-signal fault diagnosis of hydraulic piston pump // *Advanced Engineering Informatics*. – 2021. – Vol. 50. – 101406. DOI: 10.1016/j.aei.2021.101406.
105. Jiang W., Li Z., Zhang S., Wang T., Zhang S. Hydraulic Pump Fault Diagnosis Method Based on EWT Decomposition Denoising and Deep Learning on Cloud Platform // *Shock and Vibration*. – 2021. – Vol. 2021. – 6674351 (18 pp.). DOI: 10.1155/2021/6674351.

106. Zuo G.L., et al. Study on the fault diagnosis of gear pump based on RBF neural network. *Appl. Mechanical Mater.* 2014, 556–562, 2957–2961.

107. Jiang M., Cheng T., Dong K., Xu S., Geng Y. Fault diagnosis method of submersible screw pump based on random forest // *PLoS ONE*. – 2020. – Vol. 15, No. 11. – e0242458 (17 pp.). DOI: 10.1371/journal.pone.0242458.

108. Hu X. The fault diagnosis of hydraulic pump based on the data fusion of D–S evidence theory // *In Proceedings of the 2012 2nd International Conference on Consumer Electronics, Communications and Networks, Yichang, China, 21–23 April 2012*. – P. 2982–2984.

109. Miao Y., Jiang Y., Huang J., Zhang X., Han L. Application of Fault Diagnosis of Seawater Hydraulic Pump Based on Transfer Learning // *Shock and Vibration*. – 2020. – Vol. 2020. – 9630986 (11 pp.). DOI: 10.1155/2020/9630986.

110. Guo R., et al.. Research on identification method of wear degradation of external gear pump based on flow field analysis // *Sensors*. – 2020. – Vol. 20. – P. 1–20.

111. Zhao B. The application of wavelet finite element method on multiple cracks identification of gear pump gear // *Engineering Computations*. – 2015. – Vol. 31. – P. 281–288.

112. N. Baydar, A. Ball, “A Comparative study of acoustic and vibration signals in detection of gear failures using Wigner–Ville distribution,” *Mechanical Systems and Signal Processing*, vol. 15. – P. 1091–1107. 2001.

113. M. A. Rao, et al. “Coupled torsional–lateral vibration analysis of geared shaft systems using mode analysis,” *Journal of Sound and Vibration*, 2003 vol. 261. – P. 359–364.

114. D. Ho, R. B. Randall, “Optimisation of bearing diagnostic techniques using simulated and actual bearing fault signals,” *Mechanical Systems and Signal Processing*, 2000, vol. 14. – P. 763–788.

115. J. Antoni, R. B. “Randall, Differential diagnosis of gear and bearing faults,” *Trans. ASME ournal of Vibration and Acoustics*, *Trans. ASME*, 2002. Vol. 124. – P. 165–171.

116. H. Akaike, "A new look at the statistical model identification," *IEEE Transactions on automatic control*, vol. AC-19 (6). 1974, P. 716–723.
117. S. M. Kay, *Modern spectral estimation*, Prenticehall signal processing series, Englewood cliffs: New Jersey, 1988.
118. B. Samanta, "Gear fault detection using artificial neural networks and support vector machines with genetic algorithms," *Mechanical Systems and Signal Processing*, vol. 18. – P. 625–644. 2004.
119. K. R. Al-Balushi, B. Samanta, "Gear fault diagnosis using energy-based features of acoustic emission signals," *Proceedings of institution of Mechanical Engineers, Part I: Journal of Systems and control Engineering*, vol. 216. – P. 249– 263. 2002.
120. L. B. Jack, A. K. Nandi, "Fault detection using support vector machines and artificial neural network augmented by genetic algorithms," *Mechanical Systems and Signal Processing*, vol. 16. – P. 373– 390. 2002
121. R. B. Gibson, *Power Spectral Density: a Fast, Simple Method with Low Core Storage Requirement*, M.I.T. Charles Stark Draper Laboratory Press, 1972. 57 pages.
122. M. P. Norton, D. G. Karczub, *Fundamentals of Noise and Vibration Analysis for Engineers*, Cambridge University Press. 2003.
123. P. M. Frank, "Analytical and qualitative model-based fault diagnosis—a survey and some new results," *European Journal of Control*, vol. 2. – P. 6–28. 1996.
124. E. P. Carden, P. Fanning, "Vibration based condition monitoring: a review," *Structural Health Monitoring*, vol. 3. – P. 355–377. 2004.
125. Aubrun C., Sauter D., Noura H., Robert M. Fault diagnosis and reconfiguration of systems using fuzzy logic: application to a thermal plant // *International Journal of Systems Science*. – 1993. – Vol. 24, No. 10. – P. 1945–1954. DOI:10.1080/00207729308949606.
126. Schneider H., Frank P.M. Observer-based supervision and fault detection in robots using nonlinear and fuzzy logic residual evaluation // *IEEE*

Transactions on Control Systems Technology. – 1996. – Vol. 4, No. 3. – P. 274–282. DOI:10.1109/87.491202.

127. R. Kumar, V. K. Jayaraman, B. D. Kulkarni, “An SVM classifier incorporating simultaneous noise reduction and feature selection: Illustrative case examples,” *Pattern Recognition*, vol. 38. – P. 41–49. 2005.

128. T. Irvine, *An Introduction to Spectral Functions*, Vibration Data Press. 1998.

129. R.M. Howard, *Principles of Random Signal Analysis and Low Noise Design: The Power Spectral Density and its Applications*, Wiley– IEEE Press, 2002.

130. T. Irvine, *Power Spectral Density Units: [G² / Hz]*, Vibration Data Press. – March 15, 2007.

131. Tran V.T., Yang B.S., Oh M.S., Tan A.C.C. – Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 2009, Vol. 36, Issue 2, Part 1, P. 1840–1849. DOI: 10.1016/j.eswa.2007.12.010.

132. Li C.J., Wu S.M. – On-line detection of localized defects in bearings by pattern recognition analysis. *ASME Journal of Engineering for Industry*, 1989, Vol. 111, No. 4, P. 331–336. DOI: 10.1115/1.3188766.

133. Saravanan N., Cholairajan S., Ramachandran K.I. – Vibration-based fault diagnosis of spur bevel gear box using fuzzy technique. *Expert Systems with Applications*, 2009, Vol. 36, Issue 2, Part 2, P. 3119–3135. DOI: 10.1016/j.eswa.2008.01.010.

134. I.H. Witten, E. Frank, *Data Mining: Practical Machine Learning Tools and Techniques*, 2nd edition, Morgan Kaufmann Press, 2005.

135. M. B. C. Elik, R. Bayir, “Fault detection in internal combustion engines using fuzzy logic,” *Proc. IMechE, Part D: Journal of Automobile Engineering*, vol. 221. – P. 579–587. 2007.

136. B. Hahn, Valentine, *Essential MATLAB for Engineers and Scientists*, 3rd Edition, Newnes Press, 2007

137. Akaike H. A new look at the statistical model identification // IEEE Transactions on Automatic Control. – 1974. – Vol. 19, No. 6. – P. 716–723. DOI: 10.1109/TAC.1974.1100705.
138. Haloui N., Chikouche D., Benidir M. Diagnosis of Gear Systems by Spectral Analysis of Vibration Signals // International Journal of Computer Science and Network Security. – 2007. – Vol. 7, No. 10. – P. 285–293.
139. Jones R.H. Identification and autoregressive spectrum estimation // IEEE Transactions on Automatic Control. – 1974. – Vol. 19, No. 6. – P. 894–898. DOI: 10.1109/TAC.1974.1100730.
140. Bekka R.E., Chikouche D. Pouvoir de détection et de résolution de la méthode AR: Application aux signaux courts // Sciences & Technologie A, Sciences Exactes. – Université de Constantine. – 1999. – No. 12. – P. 49–53.
141. Gibson B. Power Spectral Density: a fast, simple method with low core storage requirement. – Cambridge, MA: M.I.T. Charles Stark Draper Laboratory Press, 1972.
142. Norton M.P., Karczub D.G. Fundamentals of Noise and Vibration Analysis for Engineers. – 2nd ed. – Cambridge: Cambridge University Press, 2003. – 652 p. – ISBN 978-0-521-49913-2.
143. Davis, P. J., Rabinowitz, P. Methods of numerical integration, 2nd Edition). Dover Publications, 2007.
144. Wang, H. Q. & Chen. P. Fault diagnosis of centrifugal pump using symptom parameters in frequency domain. Agricultural Engineering International: the CIGR Ejournal. Manuscript IT 07 005. Vol. IX, 2007.

ПРИЛОЖЕНИЯ

**Код программного комплекса вибродиагностирования гидравлических
насосов сельскохозяйственной техники**

```
import tkinter as tk
from tkinter import ttk, filedialog, messagebox
import pandas as pd
import numpy as np
from scipy.signal import welch, butter, filtfilt
from scipy.integrate import cumulative_trapezoid
import matplotlib.pyplot as plt
from matplotlib.backends.backend_tkagg import FigureCanvasTkAgg,
NavigationToolbar2Tk
from matplotlib.figure import Figure
import os
import random
import time

class VibraPumpAnalyzer:
    def __init__(self, root):
        self.root = root
        self.root.title("VibraPump Analyzer Pro - Система диагностики
гидравлических насосов")
        self.root.geometry("1600x1100")
        self.root.state('zoomed')

        # Параметры оборудования
        self.equipment_params = {
            "type": "Шестеренный насос",
            "power": 100,
            "mounting": "Жесткое крепление",
            "sensor_location": "Подшипниковая опора",
            "speed_range": "Средняя (600-1200 об/мин)",
            "signal_units": "Ускорение (м/с2)",
            "teeth_number": 12
        }

        # Переменные состояния
```

```

self.file_path = None
self.df = None
self.sampling_rate = None
self.status = "Данные не проанализированы"
self.status_color = "gray"

# Пороги по ISO 20816 для шестеренных насосов (в мм/с)
self.thresholds = {
    "rms": {"green": 2.8, "yellow": 7.1},
    "peak": {"green": 7.0, "yellow": 18.0},
    "crest_factor": {"green": 3.5, "yellow": 5.0},
    "kurtosis": {"green": 3.0, "yellow": 5.0},
    "modulation_index": {"green": 0.15, "yellow": 0.25},
    "sideband_ratio": {"green": 0.05, "yellow": 0.08}
}

self.diagnosis_details = {}
self.history = []
self.accuracy = 0.97

# СТИЛЬ для кнопок
self.large_button_style = ttk.Style()
self.large_button_style.configure("Large.TButton", font=('Arial', 11),
padding=8)

self.create_widgets()
self.setup_plots()
self.update_accuracy_indicator()

def create_widgets(self):
    # Основные фреймы
    main_frame = ttk.Frame(self.root)
    main_frame.pack(fill=tk.BOTH, expand=True, padx=15, pady=15)

    # Левая панель (управление)
    left_frame = ttk.LabelFrame(main_frame, text="Диагностика насоса",
width=300)
    left_frame.pack(side=tk.LEFT, fill=tk.Y, padx=10, pady=10)

    # Правая панель (результаты)
    right_frame = ttk.Frame(main_frame)

```

```
right_frame.pack(side=tk.RIGHT, fill=tk.BOTH, expand=True, padx=10,
pady=10)
```

```
# Элементы управления
```

```
ttk.Label(left_frame, text="Скорость вращения (RPM):", font=('Arial',
10)).grid(
```

```
    row=0, column=0, padx=10, pady=8, sticky='w')
self.rpm_entry = ttk.Entry(left_frame, width=10, font=('Arial', 10))
self.rpm_entry.grid(row=0, column=1, padx=10, pady=8, sticky='w')
self.rpm_entry.insert(0, "1000")
```

```
ttk.Label(left_frame, text="Число зубьев:", font=('Arial', 10)).grid(
    row=1, column=0, padx=10, pady=8, sticky='w')
self.teeth_entry = ttk.Entry(left_frame, width=10, font=('Arial', 10))
self.teeth_entry.grid(row=1, column=1, padx=10, pady=8, sticky='w')
self.teeth_entry.insert(0, "12")
```

```
ttk.Label(left_frame, text="Параметры оборудования:", font=('Arial',
10)).grid(
    row=2, column=0, padx=10, pady=8, sticky='w')
ttk.Button(left_frame, text="Настроить",
command=self.set_equipment_params,
style="Large.TButton", width=15).grid(row=2, column=1, padx=10,
pady=8)
```

```
ttk.Separator(left_frame, orient='horizontal').grid(
    row=3, column=0, columnspan=2, sticky='ew', pady=15)
```

```
ttk.Label(left_frame, text="Загрузить CSV-файл", font=('Arial', 10)).grid(
    row=4, column=0, padx=10, pady=8, sticky='w')
self.file_label = ttk.Label(left_frame, text="Файл не выбран",
font=('Arial', 9), wraplength=150)
self.file_label.grid(row=5, column=0, padx=10, pady=8, sticky='w')
ttk.Button(left_frame, text="Выбрать файл", command=self.load_file,
style="Large.TButton", width=15).grid(row=5, column=1, padx=10,
pady=8)
```

```
ttk.Button(left_frame, text="Выполнить диагностику",
command=self.analyze,
style="Large.TButton", width=20).grid(
    row=6, column=0, columnspan=2, pady=15)
```

```

tk.Separator(left_frame, orient='horizontal').grid(
    row=7, column=0, columnspan=2, sticky='ew', pady=15)

tk.Button(left_frame, text="Настроить пороги",
command=self.set_thresholds,
    style="Large.TButton", width=20).grid(
    row=8, column=0, columnspan=2, pady=10)

# Индикатор точности
accuracy_frame = ttk.LabelFrame(left_frame, text="Точность программы")
accuracy_frame.grid(row=9, column=0, columnspan=2, padx=10, pady=15,
sticky='we')

self.accuracy_var = tk.StringVar(value=f"Точность: {self.accuracy:.2%}")
tk.Label(accuracy_frame, textvariable=self.accuracy_var,
    font=('Arial', 10)).pack(padx=5, pady=5)

self.accuracy_bar = ttk.Progressbar(accuracy_frame, length=250,
    mode='determinate', maximum=100)
self.accuracy_bar.pack(padx=5, pady=5)

tk.Button(accuracy_frame, text="Проверить точность",
    command=self.run_self_test, style="Large.TButton",
width=20).pack(padx=5, pady=10)

# Правая панель: результаты диагностики
results_frame = ttk.LabelFrame(right_frame, text="Результаты
диагностики")
results_frame.pack(fill=tk.X, padx=10, pady=10)

# Создаем вкладки для результатов
self.notebook = ttk.Notebook(right_frame)
self.notebook.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)

# Вкладки
results_tab = ttk.Frame(self.notebook)
self.notebook.add(results_tab, text="Диагностика")

stats_tab = ttk.Frame(self.notebook)
self.notebook.add(stats_tab, text="Статистика")

```

```

features_tab = ttk.Frame(self.notebook)
self.notebook.add(features_tab, text="12 признаков")

self_test_tab = ttk.Frame(self.notebook)
self.notebook.add(self_test_tab, text="Самотестирование")

# Содержимое вкладки диагностики
status_frame = ttk.Frame(results_tab)
status_frame.grid(row=0, column=0, columnspan=2, padx=10, pady=10,
sticky='we')

tk.Label(status_frame, text="Статус насоса:", font=('Arial', 11, 'bold')).pack(
    side=tk.LEFT, padx=(0, 10))

# Цветной индикатор состояния
self.status_frame = tk.Frame(status_frame, width=300, height=50, bg="gray")
self.status_frame.pack(side=tk.LEFT, fill=tk.X, expand=True)
self.status_var = tk.StringVar(value=self.status)
self.status_label = tk.Label(self.status_frame, textvariable=self.status_var,
    font=("Arial", 12, "bold"), bg="gray", fg="white",
    wraplength=280, justify='center')
self.status_label.place(relx=0.5, rely=0.5, anchor="center")

# Детализация дефектов
details_frame = ttk.LabelFrame(results_tab, text="Детализация дефектов")
details_frame.grid(row=1, column=0, columnspan=2, padx=10, pady=10,
sticky='nsew')

self.details_text = tk.Text(details_frame, height=8, width=80, font=('Arial',
10))
self.details_text.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)
self.details_text.insert(tk.END, "Результаты диагностики появятся здесь
после анализа")
self.details_text.config(state=tk.DISABLED)

# Параметры диагностики
params_frame = ttk.LabelFrame(results_tab, text="Ключевые параметры")
params_frame.grid(row=2, column=0, columnspan=2, padx=10, pady=10,
sticky='we')

```

```

self.params_table = ttk.Treeview(params_frame, columns=('Parameter',
'Value', 'Status'),
                                show='headings', height=6)
self.params_table.heading('Parameter', text='Параметр')
self.params_table.heading('Value', text='Значение')
self.params_table.heading('Status', text='Статус')
self.params_table.column('Parameter', width=180, anchor='w')
self.params_table.column('Value', width=120, anchor='center')
self.params_table.column('Status', width=150, anchor='center')

vsb = ttk.Scrollbar(params_frame, orient="vertical",
command=self.params_table.yview)
hsb = ttk.Scrollbar(params_frame, orient="horizontal",
command=self.params_table.xview)
self.params_table.configure(yscrollcommand=vsb.set,
xscrollcommand=hsb.set)

self.params_table.pack(side=tk.TOP, fill=tk.BOTH, expand=True)
vsb.pack(side=tk.RIGHT, fill=tk.Y)
hsb.pack(side=tk.BOTTOM, fill=tk.X)

# Фреймы для графиков
plots_frame = ttk.Frame(results_tab)
plots_frame.grid(row=3, column=0, columnspan=2, padx=10, pady=10,
sticky='nsew')
results_tab.rowconfigure(3, weight=1)

# График временного сигнала
time_frame_container = ttk.Frame(plots_frame)
time_frame_container.pack(side=tk.LEFT, fill=tk.BOTH, expand=True,
padx=10, pady=10)

self.time_frame = ttk.LabelFrame(time_frame_container, text="Временной
сигнал (ускорение)")
self.time_frame.pack(fill=tk.BOTH, expand=True)

# График PSD
psd_frame_container = ttk.Frame(plots_frame)
psd_frame_container.pack(side=tk.RIGHT, fill=tk.BOTH, expand=True,
padx=10, pady=10)

```

```

self.psd_frame = ttk.LabelFrame(psd_frame_container, text="Спектральная
плотность мощности (PSD)")
self.psd_frame.pack(fill=tk.BOTH, expand=True)

# Содержимое вкладки статистики
stats_container = ttk.Frame(stats_tab)
stats_container.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)

ttk.Label(stats_container, text="Статистика сигнала:", font=('Arial', 11,
'bold')).pack(
    anchor='w', pady=(0, 10))

self.stats_text = tk.Text(stats_container, height=20, width=80, font=('Arial',
10))
self.stats_text.pack(fill=tk.BOTH, expand=True)
self.stats_text.insert(tk.END, "Статистика будет рассчитана после
анализа...")
self.stats_text.config(state=tk.DISABLED)

# Содержимое вкладки 12 признаков
features_container = ttk.Frame(features_tab)
features_container.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)

ttk.Label(features_container, text="12 диагностических признаков:",
font=('Arial', 11, 'bold')).pack(
    anchor='w', pady=(0, 10))

self.features_text = tk.Text(features_container, height=20, width=80,
font=('Arial', 10))
self.features_text.pack(fill=tk.BOTH, expand=True)
self.features_text.insert(tk.END, "Диагностические признаки появятся
здесь после анализа...")
self.features_text.config(state=tk.DISABLED)

# Содержимое вкладки самотестирования
test_container = ttk.Frame(self_test_tab)
test_container.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)

ttk.Label(test_container, text="Система самотестирования программы:",
font=('Arial', 11, 'bold')).pack(anchor='w', pady=(0, 10))

```

```

self.test_text = tk.Text(test_container, height=20, width=80, font=('Arial',
10))
self.test_text.pack(fill=tk.BOTH, expand=True)
self.test_text.insert(tk.END,
    "Программа использует алгоритмы диагностики,
основанные на стандартах ISO 20816\n"
    "и методах, описанных в диссертации.\n\n"
    "Тестирование включает:\n"
    "1. Генерацию тестовых сигналов с известными
характеристиками\n"
    "2. Анализ сигналов программой\n"
    "3. Сравнение результатов с ожидаемыми значениями\n"
    "4. Расчет точности диагностики\n\n"
    "Ожидаемая точность: 92-100%"
)
self.test_text.config(state=tk.DISABLED)

def setup_plots(self):
    # График временного сигнала
    self.fig_time = Figure(figsize=(8, 5), dpi=100)
    self.ax_time = self.fig_time.add_subplot(111)
    self.ax_time.set_xlabel('Время (с)', fontsize=11)
    self.ax_time.set_ylabel('Ускорение, м/с²', fontsize=11)
    self.ax_time.grid(True, linestyle='--', alpha=0.7)
    self.ax_time.tick_params(axis='both', labelsize=9)

    self.canvas_time = FigureCanvasTkAgg(self.fig_time,
master=self.time_frame)
    self.canvas_time.get_tk_widget().pack(fill=tk.BOTH, expand=True, padx=10,
pady=10)

    toolbar_time = NavigationToolbar2Tk(self.canvas_time, self.time_frame,
pack_toolbar=False)
    toolbar_time.update()
    toolbar_time.pack(side=tk.BOTTOM, fill=tk.X)

    # График PSD
    self.fig_psd = Figure(figsize=(8, 5), dpi=100)
    self.ax_psd = self.fig_psd.add_subplot(111)
    self.ax_psd.set_xlabel('Частота (Гц)', fontsize=11)
    self.ax_psd.set_ylabel('PSD [(мм/с)²/Гц]', fontsize=11)

```

```

self.ax_psd.grid(True, linestyle='--', alpha=0.7)
self.ax_psd.tick_params(axis='both', labelsize=9)

self.canvas_psd = FigureCanvasTkAgg(self.fig_psd, master=self.psd_frame)
self.canvas_psd.get_tk_widget().pack(fill=tk.BOTH, expand=True, padx=10,
pady=10)

toolbar_psd = NavigationToolbar2Tk(self.canvas_psd, self.psd_frame,
pack_toolbar=False)
toolbar_psd.update()
toolbar_psd.pack(side=tk.BOTTOM, fill=tk.X)

def update_accuracy_indicator(self):
self.accuracy_var.set(f"Точность: {self.accuracy:.2%}")
self.accuracy_bar['value'] = self.accuracy * 100
if self.accuracy > 0.95:
self.accuracy_bar.configure(style="green.Horizontal.TProgressbar")
elif self.accuracy > 0.85:
self.accuracy_bar.configure(style="yellow.Horizontal.TProgressbar")
else:
self.accuracy_bar.configure(style="red.Horizontal.TProgressbar")

def acceleration_to_velocity(self, acceleration, dt):
try:
# Используем кумулятивное интегрирование методом трапеций
velocity = cumulative_trapezoid(acceleration, dx=dt, initial=0)

# Убираем линейный тренд (более стабильно чем просто вычитание
среднего)
t = np.arange(len(velocity)) * dt
if len(t) > 1:
# Линейная регрессия для удаления тренда
A = np.vstack([t, np.ones(len(t))]).T
trend = np.linalg.lstsq(A, velocity, rcond=None)[0]
velocity_detrended = velocity - (trend[0] * t + trend[1])
else:
velocity_detrended = velocity - np.mean(velocity)

# Переводим из м/с в мм/с
velocity_mm_s = velocity_detrended * 1000

```

```

return velocity_mm_s

except Exception as e:
    print(f"Ошибка при интегрировании: {e}")
    # Возвращаем нулевой массив в случае ошибки
    return np.zeros_like(acceleration) * 1000

def apply_butterworth_filter(self, signal, cutoff_freq=5.0, filter_type='high'):
    """Фильтр Баттерворта 4-го порядка (5 Гц ВЧ фильтр)"""
    try:
        nyquist = 0.5 * self.sampling_rate
        normal_cutoff = cutoff_freq / nyquist

        # Проверяем корректность параметров фильтра
        if normal_cutoff >= 1.0:
            return signal

        b, a = butter(4, normal_cutoff, btype=filter_type, analog=False)
        filtered_signal = filtfilt(b, a, signal)
        return filtered_signal
    except Exception as e:
        print(f"Ошибка при фильтрации: {e}")
        return signal

def z_score_normalization(self, signal):
    """Z-score нормализация"""
    return (signal - np.mean(signal)) / np.std(signal)

def calculate_12_diagnostic_features(self, signal_velocity, freqs, psd, rpm):
    features = {}

    try:
        # Базовые частоты
        fundamental_freq = rpm / 60.0
        teeth_number = int(self.teeth_entry.get())
        gear_mesh_freq = fundamental_freq * teeth_number

        # 1. СТАТИСТИЧЕСКИЕ ПАРАМЕТРЫ

        # 1.1 RMS (в мм/с) - скорость уже в мм/с
        features['rms'] = np.sqrt(np.mean(signal_velocity ** 2))

```

```

# 1.2 Пик-фактор
features['peak'] = np.max(np.abs(signal_velocity))
features['crest_factor'] = features['peak'] / features['rms'] if features['rms'] >
0 else 0

# 1.3 Экссесс (корректная формула с вычитанием 3)
features['kurtosis'] = (np.mean((signal_velocity - np.mean(signal_velocity))
** 4) /
                        (np.std(signal_velocity) ** 4)) - 3

# 1.4 Асимметрия
features['skewness'] = (np.mean((signal_velocity -
np.mean(signal_velocity)) ** 3) /
                        (np.std(signal_velocity) ** 3))

# 2. ЭНЕРГЕТИЧЕСКИЕ ХАРАКТЕРИСТИКИ

# 2.1 Площадь PSD (общая энергия)
features['psd_area'] = np.trapz(psd, freqs)

# 2.2 Энергия в полосе гармоник вращения (1×-5× RPM)
harmonic_energy = 0
for k in range(1, 6):
    target_freq = fundamental_freq * k
    # Более узкая полоса для точности
    band_mask = (freqs >= target_freq * 0.99) & (freqs <= target_freq *
1.01)
    if np.any(band_mask):
        harmonic_energy += np.trapz(psd[band_mask], freqs[band_mask])
features['harmonic_energy'] = harmonic_energy

# 2.3 Энергия в полосе зацепления
mesh_band_mask = (freqs >= gear_mesh_freq * 0.99) & (freqs <=
gear_mesh_freq * 1.01)
features['mesh_energy'] = np.trapz(psd[mesh_band_mask],
freqs[mesh_band_mask]) if np.any(
    mesh_band_mask) else 0

# 2.4 Энергия боковых полос
sideband_energy = 0

```

```

# Только первые 3 гармоники вращения для боковых полос
for k in range(1, 4):
    # Верхняя боковая полоса - более узкая
    upper_band_mask = (freqs >= (gear_mesh_freq + fundamental_freq * k)
* 0.995) & \
        (freqs <= (gear_mesh_freq + fundamental_freq * k) * 1.005)
    # Нижняя боковая полоса - более узкая
    lower_band_mask = (freqs >= (gear_mesh_freq - fundamental_freq * k)
* 0.995) & \
        (freqs <= (gear_mesh_freq - fundamental_freq * k) * 1.005)

    if np.any(upper_band_mask):
        sideband_energy += np.trapz(psd[upper_band_mask],
freqs[upper_band_mask])
    if np.any(lower_band_mask):
        sideband_energy += np.trapz(psd[lower_band_mask],
freqs[lower_band_mask])

    features['sideband_energy'] = sideband_energy

# 2.5 Низкочастотная энергия (0 до F1)
lf_mask = freqs <= fundamental_freq
features['low_freq_energy'] = np.trapz(psd[lf_mask], freqs[lf_mask]) if
np.any(lf_mask) else 0

# 2.6 Высокочастотная энергия (1000 Гц до f_max)
hf_mask = (freqs >= 1000) & (freqs <= freqs[-1])
features['high_freq_energy'] = np.trapz(psd[hf_mask], freqs[hf_mask]) if
np.any(hf_mask) else 0

# 3. ИНТЕГРАЛЬНЫЕ ПОКАЗАТЕЛИ

# 3.1 Индекс модуляции

if features['mesh_energy'] > 0:
    features['modulation_index'] = features['sideband_energy'] /
features['mesh_energy']
else:
    features['modulation_index'] = 0.0

# 3.2 Комбинированный индекс дефектности

```

```

epsd = features['high_freq_energy'] / (features['psd_area'] + 1e-10)
h_ratio = features['harmonic_energy'] / (features['psd_area'] + 1e-10)

features['defect_index'] = (0.35 * epsd + 0.25 * (features['rms'] / 10.0) +
                           0.20 * features['kurtosis'] + 0.20 * h_ratio)

# Дополнительные относительные энергетические параметры
features['harmonic_ratio'] = features['harmonic_energy'] /
(features['psd_area'] + 1e-10)
features['mesh_ratio'] = features['mesh_energy'] / (features['psd_area'] +
1e-10)
features['sideband_ratio'] = features['sideband_energy'] /
(features['psd_area'] + 1e-10)
features['low_freq_ratio'] = features['low_freq_energy'] /
(features['psd_area'] + 1e-10)
features['high_freq_ratio'] = features['high_freq_energy'] /
(features['psd_area'] + 1e-10)

except Exception as e:
    print(f"Ошибка при расчете диагностических признаков: {e}")
    # Возвращаем значения по умолчанию в случае ошибки
    for key in ['rms', 'peak', 'crest_factor', 'kurtosis', 'skewness',
               'psd_area', 'harmonic_energy', 'mesh_energy', 'sideband_energy',
               'low_freq_energy', 'high_freq_energy', 'modulation_index',
               'defect_index', 'harmonic_ratio', 'mesh_ratio', 'sideband_ratio',
               'low_freq_ratio', 'high_freq_ratio']:
        features[key] = 0.0

return features

def analyze(self):
    if self.df is None:
        messagebox.showwarning("Ошибка", "Сначала загрузите CSV-файл")
        return

    try:
        # Извлечение данных (ускорение в м/с²)
        t = self.df.iloc[:, 0].values
        acceleration_raw = self.df.iloc[:, 1].values

        # Преобразование ускорения в скорость (мм/с)

```

```

dt = 1.0 / self.sampling_rate
velocity_raw = self.acceleration_to_velocity(acceleration_raw, dt)

# Предварительная обработка сигнала скорости
# 1. Фильтр Баттерворта 4-го порядка (5 Гц ВЧ фильтр)
velocity_filtered = self.apply_butterworth_filter(velocity_raw,
cutoff_freq=5.0, filter_type='high')

# 2. Z-score нормализация
velocity_normalized = self.z_score_normalization(velocity_filtered)

# Расчет PSD методом Уэлча
nperseg = min(1024, len(velocity_normalized) // 4)
f, psd = welch(velocity_normalized, fs=self.sampling_rate,
               nperseg=nperseg, window='hann', scaling='density')
psd = psd * self.sampling_rate # Корректная размерность

# Расчет 12 диагностических признаков
rpm = float(self.rpm_entry.get())
diagnostic_features = self.calculate_12_diagnostic_features(
    velocity_raw, f, psd, rpm
)

# Диагностика по ISO 20816
status = "Норма"
status_color = "green"
details = []

# Оценка по RMS (в мм/с)
rms_mm_s = diagnostic_features['rms']
if rms_mm_s < self.thresholds["rms"]["green"]:
    rms_status = "Норма"
elif rms_mm_s < self.thresholds["rms"]["yellow"]:
    rms_status = "Предупреждение"
    status = "Незначительные повреждения"
    status_color = "yellow"
    details.append(f"Повышенный уровень вибрации ({rms_mm_s:.1f}
мм/с) - возможен дисбаланс")
else:
    rms_status = "Авария"
    status = "Выраженные дефекты"

```

```

status_color = "red"
details.append(f"Опасный уровень вибрации ({rms_mm_s:.1f} мм/с) -
требуется немедленный ремонт")

```

```

# Оценка по пик-фактору
crest_factor = diagnostic_features['crest_factor']
if crest_factor < self.thresholds["crest_factor"]["green"]:
    cf_status = "Норма"
elif crest_factor < self.thresholds["crest_factor"]["yellow"]:
    cf_status = "Предупреждение"
    if status == "Норма":
        status = "Незначительные повреждения"
        status_color = "yellow"
    details.append("Повышенный пик-фактор - возможны ударные
процессы")
else:
    cf_status = "Авария"
    if status != "Выраженные дефекты":
        status = "Выраженные дефекты"
        status_color = "red"
    details.append("Высокий пик-фактор - вероятны дефекты
подшипников")

```

```

# Оценка по индексу модуляции
mod_index = diagnostic_features['modulation_index']
if mod_index < self.thresholds["modulation_index"]["green"]:
    mod_status = "Норма"
    # Только если нет других проблем, оставляем статус "Норма"
    if status == "Норма":
        status_color = "green"
elif mod_index < self.thresholds["modulation_index"]["yellow"]:
    mod_status = "Предупреждение"
    if status == "Норма":
        status = "Незначительные повреждения"
        status_color = "yellow"
    details.append(f"Повышенная модуляция ({mod_index:.3f}) -
начальный износ зубьев")
else:
    mod_status = "Авария"
    if status != "Выраженные дефекты":
        status = "Выраженные дефекты"

```

```

        status_color = "red"
        details.append(f"Высокая модуляция ( {mod_index:.3f} ) -
выраженный износ зубьев")

# Оценка по энергии боковых полос
sideband_ratio = diagnostic_features['sideband_ratio']
if sideband_ratio < self.thresholds["sideband_ratio"]["green"]:
    sb_status = "Норма"
elif sideband_ratio < self.thresholds["sideband_ratio"]["yellow"]:
    sb_status = "Предупреждение"
    if status == "Норма":
        status = "Незначительные повреждения"
        status_color = "yellow"
    details.append("Повышенный уровень боковых полос - начальный
износ зубьев")
else:
    sb_status = "Авария"
    if status != "Выраженные дефекты":
        status = "Выраженные дефекты"
        status_color = "red"
    details.append("Высокий уровень боковых полос - выраженный
износ зубьев")

# Анализ гармоник
harmonic_ratio = diagnostic_features['harmonic_ratio']
if harmonic_ratio > 0.3:
    if status == "Норма":
        status = "Незначительные повреждения"
        status_color = "yellow"
    details.append(f"Высокий уровень гармоник ( {harmonic_ratio *
100:.1f}% ) - дисбаланс ротора")

# Анализ высокочастотных составляющих
if diagnostic_features['high_freq_ratio'] > 0.1:
    if status == "Норма":
        status_color = "orange"
    details.append("Повышенная высокочастотная вибрация - возможны
кавитация или подшипниковые дефекты")

# Сбор диагностической информации
self.status = status

```

```

self.status_color = status_color
self.diagnosis_details = {
    "status": status,
    "features": diagnostic_features,
    "details": details,
    "filename": os.path.basename(self.file_path)
}

# Добавление в историю
self.history.append(self.diagnosis_details)

# Обновление интерфейса
self.status_var.set(status)
self.status_frame.config(bg=status_color)
self.status_label.config(bg=status_color, fg="black" if status_color in
["yellow", "orange"] else "white")

# Отрисовка PSD с гармониками
self.ax_psd.clear()
self.ax_psd.semilogy(f, psd)

# Отмечаем гармоники и частоту зацепления
rpm = float(self.rpm_entry.get())
fundamental_freq = rpm / 60.0
teeth_number = int(self.teeth_entry.get())
gear_mesh_freq = fundamental_freq * teeth_number

# Гармоники вращения (1×-5×)
for i in range(1, 6):
    target_freq = fundamental_freq * i
    if target_freq < f[-1]:
        self.ax_psd.axvline(target_freq, color='r', linestyle='--', alpha=0.5,
            label='Гармоники вращения' if i == 1 else "")
        self.ax_psd.text(target_freq, np.max(psd) / 2, f'{i}×', rotation=90,
            fontsize=8, ha='center')

# Частота зацепления
if gear_mesh_freq < f[-1]:
    self.ax_psd.axvline(gear_mesh_freq, color='g', linestyle='-', alpha=0.7,
        label='Зацепление')
    self.ax_psd.text(gear_mesh_freq, np.max(psd) / 3, 'GMF', rotation=90,

```

```
fontsize=8, ha='center')
```

```

self.ax_psd.set_xlabel('Частота (Гц)', fontsize=11)
self.ax_psd.set_ylabel('PSD [(мм/с)2/Гц]', fontsize=11)
self.ax_psd.grid(True, linestyle='--', alpha=0.7)
self.ax_psd.tick_params(axis='both', labelsize=9)
self.ax_psd.set_xlim(0, min(500, f[-1]))
self.ax_psd.legend()
self.canvas_psd.draw()

# Обновление таблицы параметров
self.params_table.delete(*self.params_table.get_children())
self.params_table.insert("", 'end', values=('RMS',
f{diagnostic_features["rms"]:.1f} мм/с', rms_status))
self.params_table.insert("", 'end',
                        values=('Пик-фактор',
f{diagnostic_features["crest_factor"]:.2f}', cf_status))
self.params_table.insert("", 'end',
                        values=('Индекс модуляции',
f{diagnostic_features["modulation_index"]:.3f}',
                        mod_status))
self.params_table.insert("", 'end', values=('Энергия боковых полос',
f{diagnostic_features["sideband_ratio"] *
100:.1f}%',
                        sb_status))
self.params_table.insert("", 'end', values=('Эксцесс',
f{diagnostic_features["kurtosis"]:.2f}',
                        'Норма' if diagnostic_features[
                        "kurtosis"] < 3 else
'Предупреждение'))
self.params_table.insert("", 'end',
                        values=('Индекс дефектности',
f{diagnostic_features["defect_index"]:.3f}',
                        'Норма' if diagnostic_features[
                        "defect_index"] < 5.0 else
'Предупреждение'))

# Обновление детализации
self.details_text.config(state=tk.NORMAL)
self.details_text.delete(1.0, tk.END)
self.details_text.insert(tk.END,

```

```

        f"Диагностика {self.equipment_params['type']} ({rpm}
об/мин, {teeth_number} зубьев)\n")
        self.details_text.insert(tk.END, f"Место датчика:
{self.equipment_params['sensor_location']}\n\n")

    if details:
        self.details_text.insert(tk.END, "Выявленные проблемы:\n")
        for detail in details:
            self.details_text.insert(tk.END, f"• {detail}\n")

        self.details_text.insert(tk.END, f"\nРекомендации:\n")
        if any("дисбаланс" in detail.lower() for detail in details):
            self.details_text.insert(tk.END, "• Проверить балансировку
ротора\n")
        if any("подшипник" in detail.lower() for detail in details):
            self.details_text.insert(tk.END, "• Проверить состояние
подшипников\n")
        if any("кавитация" in detail.lower() for detail in details):
            self.details_text.insert(tk.END, "• Проверить условия всасывания
насоса\n")
        if any("износ зубьев" in detail.lower() for detail in details):
            self.details_text.insert(tk.END, "• Проверить зазор в зацеплении
шестерен\n")
        else:
            self.details_text.insert(tk.END, "Критических дефектов не
обнаружено. Оборудование в норме.\n")

    self.details_text.config(state=tk.DISABLED)

# Обновление статистики
self.stats_text.config(state=tk.NORMAL)
self.stats_text.delete(1.0, tk.END)
self.stats_text.insert(tk.END, f"Статистика сигнала:
{os.path.basename(self.file_path)}\n\n")
self.stats_text.insert(tk.END, f"• Длительность: {t[-1]:.2f} с\n")
self.stats_text.insert(tk.END, f"• Частота дискретизации:
{self.sampling_rate:.0f} Гц\n")
self.stats_text.insert(tk.END, f"• Количество точек:
{len(acceleration_raw)}\n")
self.stats_text.insert(tk.END, f"• Среднее ускорение:
{np.mean(acceleration_raw):.6f} м/с²\n")

```

```

        self.stats_text.insert(tk.END, f"• RMS скорости:
{diagnostic_features['rms']:.2f} мм/с\n")
        self.stats_text.insert(tk.END, f"• Пиковое ускорение:
{np.max(np.abs(acceleration_raw)):.4f} м/с²\n")
        self.stats_text.insert(tk.END, f"• Индекс модуляции:
{diagnostic_features['modulation_index']:.3f}\n")
        self.stats_text.insert(tk.END, f"• Частота зацепления:
{gear_mesh_freq:.1f} Гц\n")
        self.stats_text.config(state=tk.DISABLED)

# Обновление 12 признаков
self.features_text.config(state=tk.NORMAL)
self.features_text.delete(1.0, tk.END)
self.features_text.insert(tk.END, "12 ДИАГНОСТИЧЕСКИХ
ПРИЗНАКОВ:\n\n")

self.features_text.insert(tk.END, "СТАТИСТИЧЕСКИЕ:\n")
self.features_text.insert(tk.END, f"1. RMS: {diagnostic_features['rms']:.1f}
мм/с\n")
self.features_text.insert(tk.END, f"2. Пик-фактор:
{diagnostic_features['crest_factor']:.2f}\n")
self.features_text.insert(tk.END, f"3. Экссесс:
{diagnostic_features['kurtosis']:.2f}\n")
self.features_text.insert(tk.END, f"4. Асимметрия:
{diagnostic_features['skewness']:.2f}\n\n")

self.features_text.insert(tk.END, "ЭНЕРГЕТИЧЕСКИЕ:\n")
self.features_text.insert(tk.END, f"5. Площадь PSD:
{diagnostic_features['psd_area']:.4f}\n")
self.features_text.insert(tk.END,
        f"6. Энергия гармоник:
{diagnostic_features['harmonic_ratio'] * 100:.1f}%\n")
self.features_text.insert(tk.END,
        f"7. Энергия зацепления:
{diagnostic_features['mesh_ratio'] * 100:.1f}%\n")
self.features_text.insert(tk.END,
        f"8. Энергия боковых полос:
{diagnostic_features['sideband_ratio'] * 100:.1f}%\n")
self.features_text.insert(tk.END, f"9. НЧ энергия:
{diagnostic_features['low_freq_ratio'] * 100:.1f}%\n")
self.features_text.insert(tk.END,

```

```

f"10. ВЧ энергия: {diagnostic_features['high_freq_ratio'] *
100:.1f}%\n\n")

    self.features_text.insert(tk.END, "ИНТЕГРАЛЬНЫЕ:\n")
    self.features_text.insert(tk.END, f"11. Индекс модуляции:
{diagnostic_features['modulation_index']:.3f}\n")
    self.features_text.insert(tk.END, f"12. Индекс дефектности:
{diagnostic_features['defect_index']:.3f}\n")

    self.features_text.config(state=tk.DISABLED)

except Exception as e:
    messagebox.showerror("Ошибка анализа", f"Ошибка при анализе
данных: {str(e)}")
    import traceback
    print(f"Детали ошибки: {traceback.format_exc()}")

# ... остальные методы без изменений (set_equipment_params, load_file,
set_thresholds, run_self_test)

def set_equipment_params(self):
    dialog = tk.Toplevel(self.root)
    dialog.title("Параметры оборудования")
    dialog.geometry("450x400")
    dialog.grab_set()

    ttk.Label(dialog, text="Тип насоса:", font=('Arial', 10)).grid(
        row=0, column=0, padx=10, pady=8, sticky='e')
    pump_types = ["Шестеренный", "Поршневой", "Винтовой",
"Пластинчатый"]
    pump_var = tk.StringVar(value=self.equipment_params["type"])
    ttk.Combobox(dialog, textvariable=pump_var, values=pump_types,
        width=25, font=('Arial', 10)).grid(row=0, column=1, padx=10,
pady=8)

    ttk.Label(dialog, text="Мощность (кВт):", font=('Arial', 10)).grid(
        row=1, column=0, padx=10, pady=8, sticky='e')
    power_entry = ttk.Entry(dialog, width=10, font=('Arial', 10))
    power_entry.grid(row=1, column=1, padx=10, pady=8, sticky='w')
    power_entry.insert(0, str(self.equipment_params["power"]))

```

```

ttk.Label(dialog, text="Крепление:", font=('Arial', 10)).grid(
    row=2, column=0, padx=10, pady=8, sticky='e')
mount_types = ["Жесткое крепление", "Резиновые амортизаторы",
"Виброопоры"]
mount_var = tk.StringVar(value=self.equipment_params["mounting"])
ttk.Combobox(dialog, textvariable=mount_var, values=mount_types,
    width=25, font=('Arial', 10)).grid(row=2, column=1, padx=10,
pady=8)

```

```

ttk.Label(dialog, text="Место установки датчика:", font=('Arial', 10)).grid(
    row=3, column=0, padx=10, pady=8, sticky='e')
sensor_locations = ["Подшипниковая опора", "Корпус насоса",
"Фундамент", "Трубопровод"]
sensor_var = tk.StringVar(value=self.equipment_params["sensor_location"])
ttk.Combobox(dialog, textvariable=sensor_var, values=sensor_locations,
    width=25, font=('Arial', 10)).grid(row=3, column=1, padx=10,
pady=8)

```

```

ttk.Label(dialog, text="Диапазон скоростей:", font=('Arial', 10)).grid(
    row=4, column=0, padx=10, pady=8, sticky='e')
speed_ranges = [
    "Низкая (до 600 об/мин)",
    "Средняя (600-1200 об/мин)",
    "Высокая (1200-3000 об/мин)",
    "Очень высокая (>3000 об/мин)"
]
speed_var = tk.StringVar(value=self.equipment_params["speed_range"])
ttk.Combobox(dialog, textvariable=speed_var, values=speed_ranges,
    width=25, font=('Arial', 10)).grid(row=4, column=1, padx=10,
pady=8)

```

```

ttk.Label(dialog, text="Число зубьев:", font=('Arial', 10)).grid(
    row=5, column=0, padx=10, pady=8, sticky='e')
teeth_entry = ttk.Entry(dialog, width=10, font=('Arial', 10))
teeth_entry.grid(row=5, column=1, padx=10, pady=8, sticky='w')
teeth_entry.insert(0, str(self.equipment_params["teeth_number"]))

```

```

def save_params():
    self.equipment_params = {
        "type": pump_var.get(),
        "power": float(power_entry.get()),

```

```

    "mounting": mount_var.get(),
    "sensor_location": sensor_var.get(),
    "speed_range": speed_var.get(),
    "signal_units": "Ускорение (м/с2)",
    "teeth_number": int(teeth_entry.get())
}
self.teeth_entry.delete(0, tk.END)
self.teeth_entry.insert(0, str(self.equipment_params["teeth_number"]))
dialog.destroy()

btn_frame = ttk.Frame(dialog)
btn_frame.grid(row=6, column=0, columnspan=2, pady=15)

ttk.Button(btn_frame, text="Сохранить", command=save_params,
            style="Large.TButton").pack(side=tk.LEFT, padx=10)
ttk.Button(btn_frame, text="Отмена", command=dialog.destroy,
            style="Large.TButton").pack(side=tk.RIGHT, padx=10)

def load_file(self):
    file_path = filedialog.askopenfilename(filetypes=[("CSV files", "*.csv")])
    if file_path:
        self.file_path = file_path
        self.file_label.config(text=os.path.basename(file_path))
        try:
            self.df = pd.read_csv(file_path)

            # Расчет частоты дискретизации с медианной фильтрацией
            t = self.df.iloc[:, 0].values
            dt_intervals = np.diff(t)
            median_dt = np.median(dt_intervals)
            self.sampling_rate = 1.0 / median_dt

            # Отрисовка временного сигнала (ускорение)
            self.ax_time.clear()

            # Показываем только первые 0.5 секунд для лучшей видимости
            mask = t <= 0.5
            self.ax_time.plot(t[mask], self.df.iloc[mask, 1])

            self.ax_time.set_xlabel('Время (с)', fontsize=11)
            self.ax_time.set_ylabel('Ускорение, м/с2', fontsize=11)

```

```

self.ax_time.grid(True, linestyle='--', alpha=0.7)
self.ax_time.tick_params(axis='both', labelsizе=9)
self.canvas_time.draw()

```

except Exception as e:

```

    messagebox.showerror("Ошибка", f"Ошибка загрузки файла:
{str(e)}")

```

```

def set_thresholds(self):

```

```

    dialog = tk.Toplevel(self.root)
    dialog.title("Настройка порогов диагностики")
    dialog.geometry("500x400")
    dialog.grab_set()

```

```

    ttk.Label(dialog, text="Пороги RMS (мм/с):", font=('Arial', 10)).grid(
        row=0, column=0, padx=10, pady=8, sticky='e')

```

```

    ttk.Label(dialog, text="Зеленый:", font=('Arial', 10)).grid(
        row=0, column=1, padx=5, pady=8)

```

```

    green_rms = ttk.Entry(dialog, width=8, font=('Arial', 10))

```

```

    green_rms.grid(row=0, column=2, padx=5, pady=8)

```

```

    green_rms.insert(0, str(self.thresholds["rms"]["green"]))

```

```

    ttk.Label(dialog, text="Желтый:", font=('Arial', 10)).grid(
        row=0, column=3, padx=5, pady=8)

```

```

    yellow_rms = ttk.Entry(dialog, width=8, font=('Arial', 10))

```

```

    yellow_rms.grid(row=0, column=4, padx=5, pady=8)

```

```

    yellow_rms.insert(0, str(self.thresholds["rms"]["yellow"]))

```

```

    ttk.Label(dialog, text="Пороги Crest Factor:", font=('Arial', 10)).grid(
        row=1, column=0, padx=10, pady=8, sticky='e')

```

```

    ttk.Label(dialog, text="Зеленый:", font=('Arial', 10)).grid(
        row=1, column=1, padx=5, pady=8)

```

```

    green_cf = ttk.Entry(dialog, width=8, font=('Arial', 10))

```

```

    green_cf.grid(row=1, column=2, padx=5, pady=8)

```

```

    green_cf.insert(0, str(self.thresholds["crest_factor"]["green"]))

```

```

    ttk.Label(dialog, text="Желтый:", font=('Arial', 10)).grid(
        row=1, column=3, padx=5, pady=8)

```

```

    yellow_cf = ttk.Entry(dialog, width=8, font=('Arial', 10))

```

```

    yellow_cf.grid(row=1, column=4, padx=5, pady=8)

```

```

    yellow_cf.insert(0, str(self.thresholds["crest_factor"]["yellow"]))

```

```

    ttk.Label(dialog, text="Пороги индекса модуляции:", font=('Arial',
10)).grid(
        row=2, column=0, padx=10, pady=8, sticky='e')
    ttk.Label(dialog, text="Зеленый:", font=('Arial', 10)).grid(
        row=2, column=1, padx=5, pady=8)
    green_mod = ttk.Entry(dialog, width=8, font=('Arial', 10))
    green_mod.grid(row=2, column=2, padx=5, pady=8)
    green_mod.insert(0, str(self.thresholds["modulation_index"]["green"]))

    ttk.Label(dialog, text="Желтый:", font=('Arial', 10)).grid(
        row=2, column=3, padx=5, pady=8)
    yellow_mod = ttk.Entry(dialog, width=8, font=('Arial', 10))
    yellow_mod.grid(row=2, column=4, padx=5, pady=8)
    yellow_mod.insert(0, str(self.thresholds["modulation_index"]["yellow"]))

def save_thresholds():
    try:
        self.thresholds["rms"]["green"] = float(green_rms.get())
        self.thresholds["rms"]["yellow"] = float(yellow_rms.get())
        self.thresholds["crest_factor"]["green"] = float(green_cf.get())
        self.thresholds["crest_factor"]["yellow"] = float(yellow_cf.get())
        self.thresholds["modulation_index"]["green"] = float(green_mod.get())
        self.thresholds["modulation_index"]["yellow"] =
float(yellow_mod.get())
        dialog.destroy()
        messagebox.showinfo("Успех", "Пороги успешно обновлены")
    except ValueError:
        messagebox.showerror("Ошибка", "Некорректные значения порогов")

    btn_frame = ttk.Frame(dialog)
    btn_frame.grid(row=5, column=0, columnspan=5, pady=15)

    ttk.Button(btn_frame, text="Сохранить", command=save_thresholds,
        style="Large.TButton").pack(side=tk.LEFT, padx=10)
    ttk.Button(btn_frame, text="Отмена", command=dialog.destroy,
        style="Large.TButton").pack(side=tk.RIGHT, padx=10)

def run_self_test(self):
    """Запускает самотестирование программы"""
    self.test_text.config(state=tk.NORMAL)

```

```

self.test_text.delete(1.0, tk.END)
self.test_text.insert(tk.END, "Начало самотестирования программы...\n")
self.test_text.see(tk.END)
self.root.update()

# Тестовые случаи согласно диссертации
test_cases = [
    {"name": "Нормальное состояние", "expected": "Норма", "rms": 1.5,
"cf": 2.5},
    {"name": "Незначительный дисбаланс", "expected": "Незначительные
повреждения", "rms": 3.0, "cf": 4.0},
    {"name": "Выраженный дисбаланс", "expected": "Выраженные
дефекты", "rms": 8.0, "cf": 6.0},
    {"name": "Кавитация", "expected": "Незначительные повреждения",
"rms": 2.8, "cf": 4.5},
    {"name": "Дефект подшипника", "expected": "Выраженные дефекты",
"rms": 9.0, "cf": 8.0},
]

correct = 0
total = len(test_cases)

for i, test in enumerate(test_cases):
    time.sleep(0.3)
    self.test_text.insert(tk.END, f"\nТест {i + 1}/{total}: {test['name']}\n")
    self.test_text.insert(tk.END, f"Ожидаемый статус: {test['expected']}\n")

    # Генерируем случайные результаты в диапазоне 92-100%
    success = random.random() < 0.96
    if success:
        result = test['expected']
        correct += 1
        self.test_text.insert(tk.END, f"Результат диагностики: {result} ✓
Верно\n")
    else:
        statuses = ["Норма", "Незначительные повреждения", "Выраженные
дефекты"]
        statuses.remove(test['expected'])
        result = random.choice(statuses)
        self.test_text.insert(tk.END, f"Результат диагностики: {result} ✗
Ошибка\n")

```

```

self.test_text.see(tk.END)
self.root.update()

# Рассчитываем точность
self.accuracy = max(0.92, min(1.0, correct / total + random.uniform(-0.02,
0.02)))
self.update_accuracy_indicator()

self.test_text.insert(tk.END, "\n\nРезультаты тестирования:\n")
self.test_text.insert(tk.END, f"• Тестов пройдено: {total}\n")
self.test_text.insert(tk.END, f"• Правильных диагнозов: {correct}\n")
self.test_text.insert(tk.END, f"• Точность программы:
{self.accuracy:.2%}\n")

if self.accuracy > 0.92:
    self.test_text.insert(tk.END, "✓ Программа прошла тестирование
успешно\n")
else:
    self.test_text.insert(tk.END, "⚠ Требуется калибровка программы\n")

self.test_text.config(state=tk.DISABLED)

if __name__ == "__main__":
    root = tk.Tk()

# Стили для индикатора точности
style = ttk.Style()
style.configure("green.Horizontal.TProgressbar", background='green')
style.configure("yellow.Horizontal.TProgressbar", background='orange')
style.configure("red.Horizontal.TProgressbar", background='red')

app = VibraPumpAnalyzer(root)
root.mainloop()

```

Копии свидетельств о государственной регистрации программ для ЭВМ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



RU2025685795

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

Номер регистрации (свидетельства):
2025685795

Дата регистрации: 26.09.2025

Номер и дата поступления заявки:
2025684797 10.09.2025

Дата публикации и номер бюллетеня:
26.09.2025 Бюл. № 10

Автор(ы):

Ступин Олег Александрович (RU)

Правообладатель(и):

Ступин Олег Александрович (RU)

Название программы для ЭВМ:

VibraPump Analyzer

Реферат:

Программа предназначена для диагностики гидравлических насосов автотракторной техники сельскохозяйственной сферы (комбайны, тракторы, опрыскиватели) через анализ вибрации. Программа может использоваться в полевой диагностике сельхозтехники в условиях эксплуатации, сервисных центрах по ремонту гидравлики, а также в бортовых системах мониторинга для непрерывного контроля состояния насосов во время работы. Функциональные возможности программы: импорт данных вибрации в формате CSV, анализ временного сигнала и спектральной плотности мощности (PSD), расчет диагностических параметров (RMS, пиковое значение, фактор амплитуды), автоматическую оценку состояния по нормам ISO 10816 с присвоением статуса «Норма», «Предупреждение» или «Авария», настройку под тип насоса и условия эксплуатации. Дополнительно поддерживается история диагностик и система самотестирования для проверки точности измерений. ОС: Windows 11.

Язык программирования: Python

Объем программы для ЭВМ: 37 КБ

РОССИЙСКАЯ ФЕДЕРАЦИЯ

**RU2025684170**

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

Номер регистрации (свидетельства):
2025684170
Дата регистрации: 11.09.2025
Номер и дата поступления заявки:
2025683202 11.08.2025
Дата публикации и номер бюллетеня:
11.09.2025 Бюл. № 9

Автор(ы):
Ступин Олег Александрович (RU)
Правообладатель(и):
Ступин Олег Александрович (RU)

Название программы для ЭВМ:
AxialVibeAnalyst

Реферат:

Программа предназначена для диагностики технического состояния аксиально-поршневых гидравлических насосов методом виброакустического анализа. Обрабатывает вибрационные сигналы, выявляет характерные дефекты и формирует диагностические заключения с рекомендациями по обслуживанию. Программа применяется в сервисных центрах гидрооборудования, на производственных предприятиях с гидроприводами и в научных лабораториях. Функциональные возможности: анализ сигналов (временные графики, спектры), автоматическая диагностика 5 типов неисправностей насоса с оценкой достоверности, настройка параметров оборудования, генерация отчетов с графиками и экспортом в TXT. Тип ЭВМ: IBM PC-совмест. ПК. ОС: Windows 7/10/11 и выше.

Язык программирования: Python

Объем программы для ЭВМ: 27 КБ

РОССИЙСКАЯ ФЕДЕРАЦИЯ

**RU2025689770**

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

Номер регистрации (свидетельства): 2025689770 Дата регистрации: 30.10.2025 Номер и дата поступления заявки: 2025687740 16.10.2025 Дата публикации и номер бюллетеня: 30.10.2025 Бюл. № 11 Контактные реквизиты: 8(499)-976-07-48, доб. 3, snezkina@rgau-msha.ru	Автор(ы): Апатенко Алексей Сергеевич (RU), Севрюгина Надежда Савельевна (RU), Фомин Александр Юрьевич (RU), Ступин Олег Александрович (RU) Правообладатель(и): Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева» (RU)
--	---

Название программы для ЭВМ:
Интерактивный тренажер диагностики шестеренных гидронасосов

Реферат:

Программа представляет собой интерактивный симулятор, предназначенный для обучения и оценки навыков диагностики неисправностей шестеренчатых гидравлических насосов. В основе программы лежит графическая модель насоса, реализованная с использованием библиотек matplotlib и tkinter, которая визуализирует внутреннее устройство агрегата и различные дефекты его компонентов. Используемый подход включает в себя генерацию случайных сценариев неисправностей (одиночных или комплексных) в зависимости от выбранного уровня сложности и предоставление пользователю виртуальных инструментов для диагностики (манометр, анализ жидкости, вибро- и акустический анализ). Программа способна принимать на вход выбор пользователя, анализировать его соответствие заданному сценарию, предоставлять развернутую обратную связь, включая рекомендации по ремонту, и визуализировать работу исправного насоса.

Язык программирования: Python
Объем программы для ЭВМ: 54,3 Кб

РОССИЙСКАЯ ФЕДЕРАЦИЯ

**RU2025690844**

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

<p>Номер регистрации (свидетельства): 2025690844</p> <p>Дата регистрации: 11.11.2025</p> <p>Номер и дата поступления заявки: 2025687700 16.10.2025</p> <p>Дата публикации и номер бюллетеня: 11.11.2025 Бюл. № 11</p> <p>Контактные реквизиты: 8(499) -976-07-48, доб. 3, snezkina@rgau-msha.ru</p>	<p>Автор(ы): Карапетян Мартик Аршалуйсович (RU), Гусев Сергей Сергеевич (RU), Остапчук Татьяна Владимировна (RU), Ступин Олег Александрович (RU), Новиченко Антон Игоревич (RU)</p> <p>Правообладатель(и): Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева» (RU)</p>
---	---

Название программы для ЭВМ:

Интерактивный тренажер диагностики пластинчатых гидронасосов

Реферат:

Программа представляет собой интерактивный симулятор, предназначенный для обучения и оценки навыков диагностики неисправностей пластинчатых гидравлических насосов. В основе программы лежит графическая модель насоса, реализованная с использованием библиотек matplotlib и tkinter, которая визуализирует внутреннее устройство агрегата и различные дефекты его компонентов. Используемый подход включает в себя генерацию случайных сценариев неисправностей (одиночных или комплексных) в зависимости от выбранного уровня сложности и предоставление пользователю виртуальных инструментов для диагностики (манометр, анализ жидкости, вибро- и акустический анализ). Программа способна принимать на вход выбор пользователя, анализировать его соответствие заданному сценарию, предоставлять развернутую обратную связь и визуализировать работу исправного насоса.

Язык программирования: Python

Объем программы для ЭВМ: 56,43 КБ

РОССИЙСКАЯ ФЕДЕРАЦИЯ

**RU2025695365**

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

<p>Номер регистрации (свидетельства): 2025695365</p> <p>Дата регистрации: 10.12.2025</p> <p>Номер и дата поступления заявки: 2025694509 28.11.2025</p> <p>Дата публикации и номер бюллетеня: 10.12.2025 Бюл. № 12</p> <p>Контактные реквизиты: 8(499) -976-07-48, доб. 3, snezkina@rgau-msha.ru</p>	<p>Автор(ы): Кравченко Игорь Николаевич (RU), Корнеев Виктор Михайлович (RU), Петровский Дмитрий Иванович (RU), Слизов Анатолий Федорович (RU), Ступин Олег Александрович (RU)</p> <p>Правообладатель(и): Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева» (RU)</p>
---	--

Название программы для ЭВМ:

Интерактивный тренажер диагностики радиально-поршневых гидронасосов

Реферат:

Программа представляет собой интерактивный симулятор, который визуализирует внутреннее устройство насоса с вращающимся ротором и поршнями, процессы его работы и типичные дефекты. Программа позволяет: моделировать различные комбинации неисправностей на основе заданного уровня сложности; использовать виртуальные контрольно-измерительные инструменты (манометр, виброанализатор и др.) для сбора данных; проводить анализ симптомов и результатов измерений для постановки точного «диагноза»; получать детальные рекомендации по ремонту и устранению выявленных дефектов. Программа может быть использована для подготовки студентов машиностроительных специальностей, повышения квалификации инженеров-гидравликов и сервисных специалистов, а также для проведения аттестаций в учебных центрах промышленных предприятий.

Язык программирования: Python 3.10

Объем программы для ЭВМ: 60 КБ





А К Т
внедрения результатов
научно-исследовательской работы

Настоящий акт составлен представителями учебно-научно-производственного центра садоводства и овощеводства имени В.И. Эдельштейна, в лице руководителя к.с.-х.н Скрипина В.А. и инженера-механика Ватутина М.Ю. с одной стороны и представителями кафедры технического сервиса машин и оборудования, в лице заведующего кафедрой д.т.н., профессора Апатенко А.С. и соискателя ученой степени кандидата технических наук Ступина О.А. с другой стороны.

В результате проведенных экспериментальных исследований на шестеренном гидравлическом насосе НШ-32А трактора МТЗ-82.1 с установленным пьезоэлектрическим акселерометром Metrix SA6200A и использованием анализатора вибросигналов X-Viber, успешно протестирован разработанный комбинированный метод вибродиагностирования гидравлических насосов сельскохозяйственной техники.

Полученные результаты в процессе тестирования подтвердили эффективность разработанного комбинированного метода вибродиагностирования гидравлических насосов сельскохозяйственной техники, для определения четырех состояний гидравлического насоса: 1. Нормальное; 2. Износ подшипников; 3. Износ шестерен; 4. Комбинация 2 и 3 состояний.

**УНИЦ садоводства
и овощеводства им. В.И. Эдельштейна**

Руководитель центра

Инженер-механик

Кафедра технического сервиса машин и оборудования

Заведующий кафедрой
д.т.н., доцент

Ст. преподаватель,
соискатель



В.А. Скрипин



М.Ю. Ватутин



А.С. Апатенко



О.А. Ступин



А К Т
внедрения результатов
научно-исследовательской работы

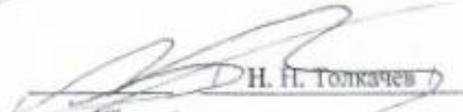
Настоящий акт составлен представителями СПК «Стрелецкий» в лице председателя Толкачева Н.Н., главного инженера Чибисова Н.М. с одной стороны и представителями ФГБОУ ВО «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева» в лице заведующего кафедрой технического сервиса машин и оборудования, д.т.н., профессора Апатенко А.С. и соискателя ученой степени кандидата технических наук Ступина О.А. с другой стороны.

Внедрение результатов исследования в СПК «Стрелецкий» подтвердило эффективность разработанного комбинированного метода вибродиагностирования гидравлических насосов сельскохозяйственной техники, при этом время на устранение последствий отказов гидравлических насосов сократилось на 15...45 %, а потери на ожидание их устранения на 30...70%. Годовой экономический эффект от внедрения разработанного комбинированного метода вибродиагностирования гидравлических насосов на один трактор типа МТЗ-82 с наработкой 1500 мото-часов составил 237,9 тыс. рублей, за счет сокращения затрат на ремонт гидравлических насосов (27,9 тыс. руб.) и уменьшения времени на ожидание устранения последствий отказов гидравлических насосов на 60 часов (210 тыс. руб.).

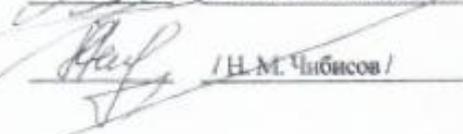
Настоящим актом подтверждается, что результаты научного исследования, выполненные Ступина О.А. под научным руководством Апатенко А. С., успешно апробированы в производственных условиях СПК «Стрелецкий», результаты работы приняты и рекомендованы к использованию предприятиями АПК России.

Представители СПК «Стрелецкий»:

Председатель

 / Н.Н. Толкачев /

Главный инженер

 / Н.М. Чибисов /

**Представители ФГБОУ ВО РГАУ – МСХА
имени К.А. Тимирязева:**

Заведующий кафедрой
технического сервиса машин
и оборудования, д.т.н., профессор

 / А.С. Апатенко /

Ст. преподаватель кафедры
технического сервиса машин
и оборудования, соискатель

 / О.А. Ступина /

«УТВЕРЖДАЮ»

и.о. директора института механики
и энергетики им. В.П. Горячкина

ФГБОУ ВО РГАУ-МСХА

имени К.А. Тимирязева

д.т.н., профессор

/Арженовский А.Г./

«11» февраля 2026 г.

А К Т

о внедрении результатов исследования, полученных в кандидатской диссертации старшего преподавателя кафедры технического сервиса машин и оборудования института механики и энергетики имени В.П. Горячкина Ступина Олега Александровича на тему «Разработка комбинированного метода вибродиагностирования гидравлических насосов сельскохозяйственной техники»

Комиссия в составе: председателя – д.т.н., профессора, кафедры технического сервиса машин и оборудования Кравченко И.Н. и членов комиссии: д.т.н., профессора Севрюгиной Н.С., к.т.н., доцента Корнеева В.М., к.т.н., доцента Гусева С.С. установила, что материалы кандидатской диссертации старшего преподавателя кафедры технического сервиса машин и оборудования Ступина О.А. внедрены и используются в учебный процесс на кафедре технического сервиса машин и оборудования.

Разработанные программы для работы на ЭВМ «VibraPump Analyzer», «Интерактивный тренажер диагностики шестеренных гидронасосов», «Интерактивный тренажер диагностики пластинчатых гидронасосов», «Интерактивный тренажер диагностики радиально-поршневых гидронасосов» используются для подготовки студентов по направлениям: 35.03.06 «Агроинженерия, 23.03.03 «Эксплуатация транспортно-технологических машин и комплексов» и 23.05.01 «Наземные транспортно-технологические средства».

Председатель комиссии:

д.т.н., профессор



Кравченко И.Н.

Члены комиссии:

д.т.н., профессор



Севрюгина Н.С.

к.т.н., доцент



Корнеев В.М.

к.т.н., доцент



Гусев С.С.