

Для цитирования

Полетаев А.А., Яблоков А.Е., Сироткин Р.О. Информационная модель прогнозирования технического состояния оборудования пищевых производств на основе анализа вибрационных сигналов / III Научно-практическая конференция «Стандартизация: траектория науки», Москва, 15 октября 2025 года // Информационно-экономические аспекты стандартизации и технического регулирования. 2025. № 6(87). С. 438–450.

УДК 004.94:681.518:006.015

ИНФОРМАЦИОННАЯ МОДЕЛЬ ПРОГНОЗИРОВАНИЯ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ОБОРУДОВАНИЯ ПИЩЕВЫХ ПРОИЗВОДСТВ НА ОСНОВЕ АНАЛИЗА ВИБРАЦИОННЫХ СИГНАЛОВ

Полетаев А.А., аспирант ФГБОУ ВО «РОСБИОТЕХ», кафедра «Промышленная инженерия», г. Москва

Яблоков А.Е., д-р техн. наук, проф., доцент кафедры «Промышленная инженерия», ФГБОУ ВО «РОСБИОТЕХ», Москва

Сироткин Р.О., канд. техн. наук, заместитель генерального директора ФГБУ «Институт стандартизации», Россия, г. Москва

Представлена информационная модель прогнозирования технического состояния приводных узлов оборудования пищевых производств на базе анализа вибрационных сигналов. Модель реализует единый конвейер: цифровая предобработка, удаление DC, нормализация, спектральная оценка методом Уэлча, окно Hann, NFFT=4096, перекрытие 50%, гибридное признаковое пространство – логарифмическая сетка спектральных амплитуд, энергии в лог-полосах, расширенная статистика, доменно-специфические агрегаты, многоклассовая нейронная классификация patternnet, trainseg и интерпретируемая интегральная оценка дефектности на основе нечеткой логики Мамдани. Эксперимент выполнен на смесителе с двухвальным рыхлителем и асинхронным электродвигателем АИР132М2У2 мощностью 11 кВт, 600 об/мин, измерительный тракт: акселерометр ДН-3М1 + АЦП L-Card E14-440D, частота дискретизации 20 кГц, контрольная точка – передний подшипник типоразмера 6308. Получена суммарная точность классификации 99,94 % на отложенной выборке при сохранении объяснимости решений через лингвистические уровни DefectLevel «Норма/Предупреждение/Крит». Предложенный подход согласован с ГОСТ Р ИСО 20816/13374 и ориентирован на практики стандартизации и технического регулирования, обеспечивая воспроизводимость измерений и поддержку обслуживания по состоянию в производственной среде. Результаты положены в основу разрабатываемой интеллектуальной автоматизированной системы диагностики оборудования производства пищевых концентратов. Научная новизна заключается в предложении гибридной модели диагностики оборудования, совмещающей нейросетевую классификацию и нечеткую интерпретацию в соответствии с ГОСТ Р ИСО 13379.

Ключевые слова: информационная модель, вибродиагностика, спектральная оценка Уэлча, обслуживание по состоянию, функциональная надежность, техническое регулирование.

INFORMATION MODEL FOR PREDICTING THE TECHNICAL CONDITION OF FOOD PRODUCTION EQUIPMENT BASED ON VIBRATION SIGNAL ANALYSIS

Poletaev A.A., Postgraduate Student, ROSBIOTECH, Department of Industrial Engineering, Moscow

Yablokov A.E., Doctor of Technical Sciences, Professor, Associate Professor of the Department of Industrial Engineering, ROSBIOTECH, Moscow

Sirotkin R.O., Ph.D., Director of the Russian Standardization Institute, Moscow

An information model for predicting the technical condition of the drive units of food production equipment based on the analysis of vibration signals is presented. The model implements a single pipeline: digital preprocessing, DC removal, normalization, Welch spectral estimation, Hann window, NFFT=4096, 50% overlap, hybrid feature space – logarithmic grid of spectral amplitudes, energies in

log bands, advanced statistics, domain-specific aggregates, multiclass neural classification patternnet, trainscg and interpreted integral estimation defects based on Mamdani's fuzzy logic. The experiment was performed on a mixer with a two-shaft ripper and an asynchronous AIR132M2U2 electric motor with a power of 11 kW, 600 rpm, measuring path: accelerometer DN-3M1 + ADC L-Card E14-440D, sampling frequency 20 kHz, control point – front bearing size 6308. The total classification accuracy of 99.94 % was obtained on the deferred sample while maintaining the explainability of solutions through linguistic levels of DefectLevel "Norm/Warning/Crete." The proposed approach is consistent with GOST R ISO 20816/13374 and is focused on standardization and technical regulation practices, ensuring reproducibility of measurements and maintenance support in the production environment. The results form the basis of the developed intelligent automated diagnostic system for food concentrate production equipment. The scientific novelty lies in the proposal of a hybrid model of equipment diagnostics combining neural network classification and fuzzy interpretation in accordance with GOST R ISO 13379.

Keywords: information model, vibration diagnostics, neural network classification, fuzzy logic Mamdani, predictive maintenance, digital signal processing, standardization, technical regulation.

Актуальность

Повышение функциональной надежности и управляемости рисками в пищевой промышленности требует перехода к обслуживанию по техническому состоянию на основе стандартизованных процедур измерения и интерпретации данных. Вибрационная диагностика – наиболее зрелый канал мониторинга для приводных узлов, однако ее практическая эффективность определяется качеством информационной модели, согласованной с ГОСТ Р ИСО 20816 и ГОСТ Р ИСО 13374, а также способностью алгоритмов давать интерпретируемые решения для служб главного инженера.

Введение

Повышение надежности и энергоэффективности технологического оборудования пищевых производств требует перехода от регламентного обслуживания к мониторингу по состоянию с использованием формализованных диагностических моделей. Наиболее информативным каналом для вращающихся узлов остается вибрационная диагностика на основе спектров виброускорения и виброскорости, сочетание классических оценок Welch/FFT и методов машинного обучения обеспечивает раннее выявление дефектов при промышленно приемлемой стоимости измерений [1–3]. Современные обзоры и академические исследования подтверждают результативность глубоких моделей и гибридных конвейеров обработки в задачах диагностики подшипников и приводов, включая сценарии, близкие к реальному производству [1, 2, 4, 5, 9, 10].

Для интеграции диагностических решений в производственный контур пищевой отрасли важно соответствие международным и национальным стандартам измерений, обработки и представления данных мониторинга состояния. Это описано в стандартах ГОСТ Р ИСО 20816, ГОСТ Р ИСО 13374, ГОСТ Р ИСО 13379, что обеспечивает воспроизводимость результатов и сопоставимость порогов [21–24]. Прикладные работы по пищевым производствам и отечественные исследования показывают, что применение нейросетевых классификаторов в сочетании с доменно-ориентированной признаковой инженерией повышает достоверность распознавания типовых дефектов: BPFO-дефекта наружного кольца подшипника, BPFI-дефекта внутреннего кольца подшипника, BSF-дефекта тел качения, перекос вала, дисбаланс ротора [11–12, 14–17, 18–20, 25].

Целью настоящей работы является разработка и верификация информационной модели прогнозирования технического состояния приводных узлов оборудования пищевых производств на основе анализа вибрационных сигналов. Предлагается гибридная архитектура: цифровая предобработка Welch, окно Hann, NFFT=4096 – признаковое представление, согласованное с нормативными диапазонами, – нейросетевая классификация по шести классам состояний – интерпретируемая интегральная оценка дефектности на базе нечеткого вывода Мамдани. Экспериментальная часть выполнена на смесителе с двухвальным

рыхлителем с асинхронным электродвигателем на 600 об/мин, где достигнута суммарная точность до 99,9% на отложенной выборке, показана согласованность решений с требованиями ГОСТ и пригодность модели для внедрения в состав разрабатываемого аппаратно-программного комплекса акселерометр – ESP32 – Raspberry Pi – Android приложение [14–17, 21–24]. Представленная работа относится к направлению информационного обеспечения стандартизации и технического регулирования в рамках создания интеллектуальных систем диагностики

Теоретическая часть и структура разрабатываемой модели диагностического комплекса

Вибрационная диагностика опирается на анализ временных реализаций виброускорений и виброскоростей и их спектральных представлений. К базовым индикаторам относятся среднеквадратичное значение RMS, пиковые и пик-пиковые значения, спектральная плотность мощности и энергетические интегралы по диагностическим полосам частот. Для подшипников качения используются характерные частоты: BPFO, BPFI (внешнее/внутреннее кольцо), BSF (элемент качения), FTF (сепаратор), а также гармоники оборотной частоты $1X/2X/\dots$ для выявления дисбаланса и перекоса. Спектральная оценка методом Уэлча – окно Ханна, перекрытие, фиксированный NFFT обеспечивает устойчивость оценок на шумных данных и совместимость с нормативными процедурами анализа [1–2, 18–19]. Дополнительную информативность дают расширенные статистики skewness, kurtosis и признаки формы спектра [14–16], [20].

Международные и национальные стандарты определяют требования к измерениям, обработке и представлению диагностических данных. ГОСТ Р ИСО 20816–1 регламентирует единицы измерения, условия съема, диапазоны частот и критерии оценки вибрационного состояния; профильные части, например для редукторов, задают отраслевые особенности [21–22]. ГОСТ Р ИСО 13374 описывает сквозной **информационный конвейер** мониторинга: сбор – проверка качества – предобработка – извлечение признаков – диагностика/прогноз – визуализация и оповещение, а также требования к форматам данных и трассируемости [23]. ГОСТ Р ИСО 13379 задает правила интерпретации результатов и принятия решений на основании диагностических признаков и контекстной информации [24]. Соблюдение этих норм критично для воспроизводимости измерений, сопоставимости результатов и последующей интеграции с системами управления качеством и техрегулированием в пищевой отрасли.

Современные обзоры показывают устойчивый рост эффективности методов ИИ для диагностики вращающихся машин по вибрационным данным: от классической признаковой инженерии с последующей классификацией MLP, Random Forest до глубоких моделей CNN, LSTM для автоматического извлечения признаков [1–2, 4–6, 11, 14–17, 25]. На практике в условиях ограниченного объема размеченных данных и необходимости интерпретируемости широко применяются компактные нейросетевые классификаторы с тщательно сформированными доменно-ориентированными признаками, такими как логарифмическая частотная сетка, энергии по полосам, пиковая структура спектра. Для повышения прозрачности решений и устойчивости к вариативности режимов целесообразно дополнять вероятностный выход нейросети нечеткой агрегацией в стиле Мамдани, которая трансформирует вероятности и энергетические индикаторы в единый индекс дефектности с лингвистическими уровнями «Норма/Предупреждение/Критическое значение» в духе подходов к интерпретации, рекомендованных государственными стандартами [23–25].

Цель работы – построить информационную модель прогнозирования технического состояния приводных узлов технологического оборудования пищевых производств по анализу вибрационных сигналов, совместимую с требованиями государственных стандартов. Задача формулируется как мультиклассовая классификация состояний по спектрам виброскорости с последующей интегральной оценкой дефектности и описана в табл. 1.

Таблица 1

Классификация состояний по спектрам виброскорости и ускорений

Классы	Норма, BPFO, BPFI, BSF, Перекос, Дисбаланс. (в данной работе без зубцовых компонентов, т.к. отсутствует редуктор в точке измерений)
Поток данных (логический конвейер)	Измерение (акселерометр) → контроль качества блока → предобработка (DC-removal, нормализация) → спектральная оценка (Welch, фикс. окно/NFFT/перекрытие) → гибридный признаковый вектор (~500+ компонент) → нейросетевая классификация (вероятности классов) → нечеткая агрегация в индекс DefectLevel $\in [0;1]$ → визуализация и оповещение
Критерии качества	Суммарная точность и точность по классам, матрица ошибок, ROC/AUC; соответствие требованиям воспроизводимости и представления данных по ГОСТ 13374, верифицируемость решений в терминах порогов по ГОСТ 20816

Такое сочетание стандартно-ориентированного конвейера обработки с компактной нейросетевой моделью и интерпретируемым нечетким слоем отражает актуальные тенденции в диагностике и прогнозировании отказов вращающихся машин [1–2, 4–6, 11, 18–19, 25]. Также конвейер учитывает специфику пищевых производств, где требования к управлению качеством и рисками технологической безопасности особенно высоки [14–17].

Разрабатываемый аппаратно-программный комплекс предназначен для непрерывного мониторинга и прогнозирования технического состояния приводных узлов технологического оборудования пищевых производств по параметрам вибрации. Комплекс реализует полный цикл: измерение → предобработка → формирование признаков → интеллектуальная классификация → интегральная оценка дефектности → передача решений и оповещение персонала. Архитектура и функциональные требования согласованы с отраслевыми стандартами мониторинга состояния машин ГОСТ Р ИСО 20816, ГОСТ Р ИСО 13374, ГОСТ Р ИСО 13379 и опираются на отечественные научные подходы к построению автоматизированных систем диагностики А.Е. Яблокова, В.Г. Благовещенского, Б.Л. Герике и других авторов [10,14–17,20].

Структурно комплекс включает четыре узла, показанных на рис. 1. Он состоит из измерительного модуля, включающего акселерометры и датчики, их ориентацию на точку измеряемого узла, узла съема и буферизации на базе микроконтроллера ESP32-S2 mini, интерфейса I²C/ UART, вычислительного узла на базе одноплатного ПК Raspberry Pi 3A+ с разработкой DSP/ML-аналитикой, базой данных, сетевыми шлюзами, мобильным приложением для Android для конфигурирования, визуализации и уведомлений, возможностью экстренных оповещений через Telegram.

Такое разнесение снижает нестабильность временных интервалов между последовательными измерениями или отсчетами АЦП относительно их номинального значения на нижнем уровне и переносит ресурсоемкие процедуры оценки спектров по Уэлчу, построения признаков, вывод HC/FIS на SBC-узел, что повышает воспроизводимость и масштабируемость решения. Логика потоков данных соответствует функциональной модели по ГОСТ 13374 (входные данные → преобразование → анализ → вывод-презентация) [23].




Рис. 1. Информационный поток данных и функциональные уровни комплекса

В качестве измерительного тракта первичный преобразователь вибрации – это тензо-МЭМС-акселерометр с опросом по I²C. Датчик устанавливается на точку узла измерений. Параметры дискретизации подбирают из условия корректного представления диагностически значимых диапазонов, согласуя с методиками ГОСТ Р ИСО 20816-1 [21]. Пример реализации данного подхода на базе датчика ДН-3М1 и АЦП L-Card описан в разделе экспериментальной части.

Узел ESP32 решает задачи инициализации канала, буферизации блоков, контроля качества RMS, пик-пик, дефекты диапазона, маркировки кадров и транспортной надежности CRC32, передачи блоков в вычислительный узел по UART до 921 600 бод. На данном уровне отсутствуют ресурсоемкие операции, что предотвращает временную нестабильность выборки.

На Raspberry Pi реализован стандартизованный конвейер обработки и вычислений, в котором реализовано удаление постоянной составляющей, нормализация, спектральная оценка методом Уэлча, гибридный признаковый вектор, многоклассовая классификация спектров виброскорости нейросетью, интерпретируемая интегральная оценка дефектности с использованием методов нечеткой логики. Схема логики принятия решения на узле Raspberry показана на рис. 2.



Рис. 2. Конвейер обработки и принятия решения на узле Raspberry

Данные и решения публикуются через локальные RESTили MQTT-шлюзы, в приборе ведется БД сырых блоков, признаков и решений SQLite, Timescale. Предусмотрены SSH-туннели для репликации в облачную БД и удаленное обновление ПО одноплатного компьютера.

Приложение Android должно обеспечивать конфигурирование ПДЗ и сети, визуализацию RMS, DefectLevel, классификации и спектры по запросу. Уведомления – предупреждение, крит с гистерезисом, экспорт скриншотов и данных для отчетов. Должны быть реализованы сценарии настройки связи, конфигурации прибора и трендов измерений. Архитектура пользовательских экранов мобильного приложения показана на рис. 3.



Рис. 3 Архитектура пользовательских экранов мобильного приложения

Процедуры измерения и агрегирования метрик соответствуют ГОСТ Р ИСО 20816-1 (общие положения измерений и оценки состояния), специфике приводов (при наличии редукторов – ГОСТ Р ИСО 20816-9), а представление данных и поток обработки согласуются

с ISO 13374 (части 1/3/4). Интерпретация результатов и логика правил – с положениями ГОСТ Р ИСО 13379-1. [21–24]

Теоретические основания определяют набор диагностических признаков и выбор архитектуры ML/FIS. ML – машинное обучение выполняет распознавание или прогнозирование технического состояния по измеренным признакам, **модуль нечеткой логики Fuzzy Inference System** выполняет интерпретацию и интегральную оценку степени дефектности в форме норма, равняющийся дефект или критическое состояние. Экспериментальная часть, описанная далее, подтверждает применимость выбранной модели, т.к. при стендовых измерениях датчиком ДН-3М1, L-Card E14-440D, $f_s=20$ кГц и обработке полученных значений в MATLAB достигается точность классификации порядка 99,9% на отложенной выборке, форма выходного индикатора DefectLevel согласуется с ожидаемыми паттернами по классам «перекос/дисбаланс/подшипниковые дефекты» [14–17].

Экспериментальная часть

Эксперимент проводился на предприятии АО «Акванова Рус», где в качестве объекта исследования выступает промышленный смеситель с двумя мешалками, диагностическая точка – нижний электродвигатель привода рыхлителя, измерение на передней точке частотных характеристик подшипника типа **6308**. Двигатель – асинхронный АИР132М2У2, номинальная скорость до 3000 об/мин; в исследуемом режиме вращение **600 об/мин** ($\approx 10,7$ Гц) под нагрузкой. Редуктора **нет**.

Средства измерений: акселерометр ДН-3М1, АЦП L-Card E14-440D, персональный компьютер с программным обеспечением L-Graph. Частота дискретизации 20 кГц на канал. Время наработки данного оборудования 5 часов. Схема установки датчика на двигателе и точка его крепления на магните показана на рис. 4.




Рис. 4. Схема установки датчика на узел рыхлителя смесителя-измельчителя
1) датчик-акселерометр, 2) асинхронный электродвигатель, 3) модуль АЦП, 4) ПК

Конвейер обработки сигналов предназначен для снятия сигнала датчиком-акселерометром с точки узла оборудования, преобразования сигнала посредством аналого-цифрового преобразователя в цифровой сигнал с помощью программного обеспечения и вывода его в код матлаб в виде сырой спектрограммы, показанной на рис. 5.




Рис. 5. Сырой сигнал

К сырой акселерограмме последовательно применяются операции удаления постоянной составляющей, применяется линейная фильтрация (в работе использовался эквивалент ФНЧ в MATLAB: `butter(4, 1000/(fs/2))`, $f_c=1$ кГц), что убирает ВЧ-шум и оставляет диагностический диапазон для данного агрегата, численное интегрирование `cumtrapz` для получения виброскорости (диагностика по скоростным признакам согласуется с ГОСТ Р ИСО 20816), спектральная оценка методом Уэлча (`pwelch`): окно **Hann**, **NFFT = 4096**, перекрытие **50 %**. Такой режим обеспечивает устойчивые оценки спектральной плотности на 0–1 кГц (скорость) и 0–5 кГц (ускорение). Примеры эталонного и «дефектных» спектров по виброскорости показаны на рис. 6.




Рис. 6. Спектрограммы преобразованного и разделенного на классы сигнала: а) дефект наружного кольца, б) дефект внутреннего кольца, в) повреждение ролика, г) перекоп вала двигателя, д) дисбаланс ротора двигателя, е) состояние нормы

В качестве базовой модели применена многослойная нейросеть (`patternnet`) с одним скрытым слоем на 40 нейронов и алгоритмом `trainscg` (ускоренный сопряженный градиент), что обеспечивает быструю и устойчивую сходимость при умеренной размерности. Функция

ошибки – MSE (для совместимости с траекторией обучения и сравнимости кривых), контроль переобучения – Early Stopping по валидационной ошибке. Выход – вектор вероятностей классов (softmax-подобная нормировка).

Оцениваются: точность по классам, суммарная точность, матрицы ошибок, гистограмма ошибок и кривые обучения/градиента. В типичном запуске достигалась суммарная точность порядка 99–100% на отложенной выборке; валид-проверки ≈ 0 , снижение градиента монотонное – признак корректной регуляризации и отсутствия «запоминания».

В качестве входного пространства признаков использованы логарифмически дискретизированные спектры виброскорости MRVv, полученные методом Уэлча – окно Hann, NFFT=4096, перекрытие 50%, диапазон 0–1000 Гц. На их основе формируется гибридный вектор: спектральные амплитуды, лог-энергии по 15 полосам, расширенная статистика mean, std, median, rms, skewness, kurtosis, а также инженерные агрегаты – энергии в диапазонах 5–30, 30–200, 200–800 Гц и их отношения; амплитуды гармоник 1X, 2X, межпиковые интервалы. Такой набор согласован с диагностической практикой виброскорости для вращательных механизмов и обеспечивает устойчивую дискриминацию классов BPFO, BSF, перекос, дисбаланс относительно состояния «Норма». Для классификации применен многослойный перцептрон patternnet, 40 нейронов, trainscg, выдающий вектор апостериорных вероятностей классов. Архитектура и диагностические метрики нейронной сети показаны на рис. 7.




Рис. 7. Архитектура и диагностические метрики нейросетевого классификатора:
а) структура и настройки классификатора, б) гистограмма ошибок, в) матрицы ошибок,
г) кривая производительности, д) состояние обучения

Для повышения интерпретируемости результатов классификации реализован интегральный индикатор дефектности DefectLevel $\in[0;1]$, получаемый на основе нечеткого вывода Мамдани (FIS) поверх постериорных вероятностей нейросетевого классификатора и энергетических признаков сигнала. В качестве входов FIS используются: максимум апостериорной вероятности по дефектным классам, нормированная RMS-энергия признакового вектора.

Функции принадлежности формируются автоматически из фактических диапазонов данных гауссовых MF для вероятности и трапецеидальные для энергии, а база правил реализует экспертную эвристику «высокая уверенность NN при высокой энергии $\Rightarrow$ высокий уровень дефектности». Выход «DefectLevel» интерпретируется в трех зонах: «Норма» в диапазоне (0; 0.4), «Предупреждение» (0.4; 0.7), «Крит» (0.7; 1).

На рис. 8 представлен профиль «DefectLevel» по всем экземплярам датасета, где ось X – порядковый номер образца, сгруппированный по классам: «Норма», BPFO, BPFI, BSF,

«Перекус», «Дисбаланс»; ось Y – интегральный уровень дефектности. Красная кривая – сырые значения FIS, синяя – скользящее усреднение «movmean», черная пунктирная – среднее по каждому классу. Вертикальные штриховые линии совпадают с границами классов по 300 образцов, горизонтальные – контрольные пороги 0.4 «Предупреждение» и 0.7 «Крит». Такое наложение позволяет одновременно видеть точечные колебания FIS-оценки, их сглаженную тенденцию и усредненный уровень по классам, что облегчает принятие решений по уставкам и верификацию корректности разметки.



Рис. 8. Интегральная оценка дефектности DefectLevel по образцам датасета

Характерный подъем DefectLevel в диапазоне образцов 1200–1500 соответствует блоку класса «Перекус»: на этих реализациях нейросеть формирует наибольшую апостериорную вероятность данного класса (за счет выраженных гармоник 1X/2X и соответствующего распределения энергии), а FIS конвертирует «уверенность + энергию» в высокий уровень дефектности. Для классов BPFO/BPFI/BSF средняя дефектность остается ниже порога «Предупреждение», поскольку спектральная активность сосредоточена в диагностических полосах BPFO/BSF, но без выраженного роста интегральной энергии, и постериорные вероятности распределяются менее «жестко», чем для «Перекуса».

Предложенный конвейер (нормированная спектрально-статистическая выборка – компактный MLP-классификатор – интерпретируемая FIS-надстройка) показал устойчивое обучение и высокую точность распознавания (≈ 99 –100 %) при физически осмысленных признаках. Интегральный индикатор дефектности корректно отражает «перекус» за счет согласованного роста вероятности NN и спектральной энергии, а подшипниковые дефекты фиксируются как развивающиеся, что удобно для раннего предупреждения. Тем самым подтверждена методологическая состоятельность алгоритма для промышленного внедрения и разработки аппаратно-программного комплекса.

Заключительная часть

В работе сформирована и верифицирована информационная модель прогнозирования технического состояния приводных узлов оборудования пищевых производств на основе анализа вибрационных сигналов. Предложен полный конвейер: предобработка – удаление DC, нормализация, спектральная оценка методом Уэлча – Hann, NFFT=4096, 50% перекрытие, формирование гибридного признака по спектрам виброскорости, мультиклассовая нейросетевая классификация из 6 состояний: норма, BPFO, BPFI, BSF, перекус, дисбаланс и интерпретируемая нечеткая агрегация Mamdani – индикатор $DefectLevel \in [0;1]$. На промышленном оборудовании проведен эксперимент и получены результаты, подтверждающие высокую диагностическую достоверность разрабатываемой модели распознавания признаков на отложенной выборке и устойчивую селективность признаков по

типам дефектов. Нечеткий уровень DefectLevel корректно разделяет режимы «Норма/Предупреждение/Крит», обеспечивая прозрачность решений для эксплуатационного персонала.

Разработана целевая архитектура внедрения (ESP32-S2 → Raspberry Pi → Android-приложение) с открытыми интерфейсами (I²C/UART/MQTT/REST), журналированием и визуализацией, что позволяет интегрировать систему в контуры технического обслуживания по состоянию службы главного инженера. Методология и формат данных согласованы с ГОСТ Р ИСО 20816, ГОСТ Р ИСО 13374/13379, что упрощает метрологическую верификацию и масштабирование решения на другие агрегаты.

Практическая значимость заключается в снижении риска внезапных отказов, сокращении простоев и в повышении управляемости качества за счет раннего обнаружения отклонений. Ограничения текущего этапа (один тип агрегата/точка установки, фиксированный режим) определяют направления продолжения работ: расширение датасета на разные режимы и узлы, мультидатчиковая конфигурация, онлайн-адаптация порогов и пилотное промышленное внедрение. В совокупности полученные результаты обосновывают внедрение интеллектуальной автоматизированной системы диагностики на предприятиях производства пищевых концентратов.

Список литературы / References

1. Bagri I., Tahiry K., Hraiba A., Touil A., Mousrij A. Vibration Signal Analysis for Intelligent Rotating Machinery Diagnosis and Prognosis: A Comprehensive Systematic Literature Review // *Vibration*. – 2024. – Т. 7, № 4. – С. 1013–1062. – DOI: 10.3390/vibration7040054. – [Электронный ресурс]. – URL: <https://www.mdpi.com/2571-631X/7/4/54> (дата обращения: 06.11.2025).
2. Matania O., Dattner I., Bortman J., Kenett R. S., Parmet Y. A systematic literature review of deep learning for vibration-based fault diagnosis of critical rotating machinery: Limitations and challenges // *Journal of Sound and Vibration*. – 2024. – Vol. 590. – Article 118562. – DOI: 10.1016/j.jsv.2024.118562. – [Электронный ресурс]. – URL: <https://doi.org/10.1016/j.jsv.2024.118562>
3. Hassan I. U., Panduru K., Walsh J. An In-Depth Study of Vibration Sensors for Condition Monitoring // *Sensors*. – 2024. – Vol. 24, No. 7. – P. 740. – DOI: 10.3390/s24020740. – [Электронный ресурс]. – URL: <https://www.mdpi.com/1424-8220/24/7/740> (дата обращения: 06.11.2025).
4. Ufymtseva S. Comparison of Machine Learning Methods for Anomaly Detection and Condition Monitoring in Rolling Bearings: Autoencoders vs LSTM: Master's Thesis. – Stockholm: KTH Royal Institute of Technology, School of Electrical Engineering and Computer Science, 2024. – 129 p. – [Электронный ресурс]. – URL: <https://kth.diva-portal.org/smash/get/diva2:1894319/FULLTEXT01.pdf> (дата обращения: 06.11.2025).
5. Lang X., Nilsson H., Mao W. A machine learning based analysis of bearing vibrations for predictive maintenance in a hydropower plant // *IOP Conference Series: Earth and Environmental Science*. – 2024. – Vol. 1411. – Article 012046. – DOI: 10.1088/1755-1315/1411/1/012046. – [Электронный ресурс]. – URL: https://research.chalmers.se/publication/544601/file/544601_Fulltext.pdf (дата обращения: 06.11.2025).
6. Kluczyk M., Grządziela A. Vibration Diagnostics of the Naval Propulsion Systems // *Zeszyty Naukowe Akademii Marynarki Wojennej*. – 2017. – Vol. 58, No. 1 (208). – P. 15–29. – DOI: 10.5604/0860889X.1237619. – [Электронный ресурс]. – URL: https://www.researchgate.net/publication/316915617_Vibration_Diagnostics_of_the_Naval_Propulsion_Systems (дата обращения: 06.11.2025).
7. Williams A. S. AI-Driven Predictive Maintenance for Reducing Energy Waste in Manufacturing Equipment // *Equipment*. – 2025. – May. – [Электронный ресурс]. – URL: https://www.researchgate.net/publication/391429896_AI-DRIVEN_PREDICTIVE_MAINTENANCE_FOR_REDUCING_ENERGY_WASTE_IN_MANUFACTURING_EQUIPMENT (дата обращения: 06.11.2025).
8. Gaye A., Ankama F., Abdulrahman I. A. Enhancing Food Safety through Predictive Maintenance: A Mathematical and Engineering Approach to Reduce Equipment-Related Contamination Risks // *International Journal of Scientific Research and Modern Technology (IJSRMIT)*. – 2025. – Vol. 4, Issue 4. – P. 474–482. – DOI: 10.38124/ijsrmt.v4i4.474. – [Электронный ресурс]. – URL: https://www.researchgate.net/publication/391556054_Enhancing_Food_Safety_through_Predictive_Maintenance_A_Mathematical_and_Engineering_Approach_to_Reduce_Equipment-Related_Contamination_Risks (дата обращения: 06.11.2025).
9. Kotas F. utilization of artificial intelligence methods in diagnostics of technical systems: bachelor thesis / Filip Kotas; supervisor Jiří Kovář. – Brno: Brno University of Technology, Faculty of Mechanical Engineering, 2021. – 46 s.

10. Яблоков А. Е. Научно-практические основы создания автоматизированных систем технического мониторинга и диагностики оборудования зерноперерабатывающих предприятий на базе нейросетевых методов анализа данных: дисс. ... д-ра техн. наук. – М.: РОСБИОТЕХ, 2022. – 377 с. – EDN UUXKVH./ Yablokov A. E. Scientific and practical bases of creation of automated systems of technical monitoring and diagnostics of equipment of grain processing enterprises on the basis of neural network methods of data analysis : diss. ... Doctor of Technical Sciences. Moscow: ROSBIOTECH, 2022. 377 p. – EDN UUXKVH.
11. Liakos K. G., et al. Machine Learning for Quality Control in the Food Industry // *Foods*. – 2018. – Vol. 7, № 4. – DOI: 10.3390/foods7040051. – [Электронный ресурс]. – URL: <https://www.mdpi.com/journal/foods> (дата обращения: 04.11.2025).
12. Semercioz-Oduncuoglu A. S., Luning P. A. Industry 4.0 technologies in quality and safety control systems in food manufacturing: A systematic techno-managerial analysis on benefits and barriers // *Trends in Food Science & Technology*. – 2025. – Vol. 163. – P. 105144. – DOI: 10.1016/j.tifs.2025.105144. – [Электронный ресурс]. – URL: <https://www.sciencedirect.com/journal/trends-in-food-science-and-technology>
13. Vibration Monitoring in Food & Beverage Market 2024–2025: аналитический обзор. – MarketIntelto, 2025. – [Электронный ресурс]. – URL: <https://marketintelto.com/report/vibration-monitoring-in-food-and-beverage-market> (дата обращения: 04.11.2025).
14. Полетаев А. А., Яблоков А. Е. Нейросетевой метод технической диагностики оборудования по спектрам виброскорости и виброускорений // *Известия Тульского государственного университета. Технические науки*. – 2024. – № 5. – С. 476–481. – DOI: 10.24412/2071-6168-2024-5-476-477./ Poletaev A. A., Yablokov A. E. Neural network method of technical diagnostics of equipment based on vibration velocity and vibration acceleration spectra // *Proceedings of Tula State University. Technical sciences*. – 2024. – No. 5. – pp. 476-481. – DOI: 10.24412/2071-6168-2024-5-476-477.
15. Яблоков А.Е., Латышев М.А., Шилина В.Д., Полетаев А.А. Технологии ИНС в задаче спектральной вибродиагностики оборудования хлебопекарного производства // *Хлебопечение России*. – 2024. – Т. 68, № 3. – С. 16–25. – [Электронный ресурс]. – URL: <https://www.hbreview.ru/index.php/hb/article/view/67> (дата обращения: 04.11.2025)./ Yablokov A. E., Latyshev M. A., Shilina V. D., Poletaev A. A. ANN technologies in the problem of spectral vibration diagnostics of bakery equipment. – 2024. – Vol. 68, No. 3. – pp. 16-25.
16. Полетаев А.А., Яблоков А.Е., Сироткин Р.О. Применение спектрального анализа вибраций производственного оборудования для повышения экологической безопасности: материалы IV Междунар. науч.-практ. конф. – М.: ВНИИ ГОЧС МЧС России, 2025. – С. 420–424. Poletaev A. A., Yablokov A. E., Sirotkin R. O. Application of spectral vibration analysis of industrial equipment to improve environmental safety : proceedings of the IV International Scientific and Practical Conference– Moscow : VNIИ GOCHS EMERCOM of Russia, 2025, pp. 420-424.
17. Сироткин Р. О., Полетаев А. А., Яблоков А. Е. Информационные технологии для удаленного мониторинга и управления оборудованием на производстве пищевых концентратов: материалы III Междунар. науч.-практ. конф. – М.: Объединенная редакция, 2024. – С. 152–158. Sirotkin R. O., Poletaev A. A., Yablokov A. E. Information technologies for remote monitoring and control of equipment in the production of food concentrates : materials of the III International Scientific and Practical Conference– Moscow : United Edition, 2024, pp. 152-158.
18. Костюков В. Н., Науменко А. П. Основы виброакустической диагностики и мониторинга машин. – Омск : Изд-во ОмГТУ, 2011. – 360 с. Kostyukov V. N., Naumenko A. P. Fundamentals vibroacoustic diagnostics and monitoring of machines. Omsk : Publishing House of OmGTU, 2011. 360 p.
19. Неразрушающий контроль: Справочник: В 8 т. / Под общ. ред. В.В. Клюева. Т. 7: В 2 кн. Кн. 1: В.И. Иванов, И.Э. Власов. Метод акустической эмиссии. Кн. 2: Ф.Я. Балицкий, А.В. Барков, Н.А. Баркова и др. Вибродиагностика. – 2-е изд., испр. – М.: Машиностроение, 2006. – 829 с.: ил./ Non-destructive testing: Handbook: In 8 volumes / Under the general editorship of V.V. Klyuev. Vol. 7: In 2 books. Book 1: V.I. Ivanov, I.E. Vlasov. Acoustic emission method. Book 2: F.Ya. Balitsky, A.V. Barkov, N.A. Barkova and others. Vibration diagnostics. – 2nd ed., ispr. – M.: Mashinostroenie, 2006. – 829 p.: ill.
20. Герике, П. Б. Применение единых критериев для диагностики и прогнозирования технического состояния подшипников / П. Б. Герике, Б. Л. Герике // *Горное оборудование и электромеханика*. – 2025. – № 4(180). – С. 76–82. – DOI 10.26730/1816-4528-2025-4-76-82. – EDN UGTLBI./ Guericke, P. B. Application of uniform criteria for diagnostics and forecasting of the technical condition of bearings / P. B. Guericke, B. L. Guericke // *Mining equipment and electromechanics*. – 2025. – № 4(180). – Pp. 76-82. – DOI 10.26730/1816-4528-2025-4-76-82. – EDN UGTLBI
21. ГОСТ Р ИСО 20816-1–2021. Вибрация. Измерения вибрации и оценка вибрационного состояния машин. Часть 1. – М.: Стандартинформ, 2021. – [Электронный ресурс]. – URL: <https://docs.cntd.ru/document/1200180878> (дата обращения: 04.11.2025) / GOST R ISO 20816-9–2023. Vibration. Vibration measurements and evaluation of the vibration condition of machines. Part 9. Gearboxes. Moscow: Standartinform, 2023.

22. ГОСТ Р ИСО 20816-9–2023. Вибрация. Измерения вибрации и оценка вибрационного состояния машин. Часть 9. Редукторы. – М.: Стандартиформ, 2023. – [Электронный ресурс]. – URL: <https://allgosts.ru/document/1200726756> (дата обращения: 04.11.2025)/
GOST R ISO 13374-1/-3/-4 . Monitoring and diagnostics of machines. Processing, transmission and presentation of data. Moscow: Standartinform, 2011-2021.
23. ГОСТ Р ИСО 13374-1/-3/-4. Мониторинг и диагностика машин. Обработка, передача и представление данных. – М.: Стандартиформ, 2011–2021. – [Электронный ресурс]. – URL: <https://www.iso.org/standard/73632.html> (дата обращения: 04.11.2025)/
GOST R ISO 13374-1/-3/-4. Monitoring and diagnostics of machines. Processing, transmission and presentation of data. Moscow : Standartinform, 2011-2021.
24. ГОСТ Р ИСО 13379-1-2015. Мониторинг и диагностика машин. Интерпретация данных и принятие решений. Часть 1. – М.: Стандартиформ, 2015. – [Электронный ресурс]. – URL: <https://allgosts.ru/document/1200170325> (дата обращения: 04.11.2025)./
GOST R ISO 13379-1-2015. Monitoring and diagnostics of machines. Data interpretation and decision-making. Part 1. Moscow: Standartinform, 2015.
25. Brink H., Richards J., Fetherolf M. Real-World Machine Learning. – Shelter Island, NY : Manning, 2016. – Рус. изд.: Бринк Х., Ричардс Д., Феверолф М. Машинное обучение. – СПб.: Питер, 2017. – 336 с.