

## О применении технологий искусственного интеллекта в задачах акустического распознавания

**А. Р. Салиева**

Санкт-Петербургский государственный электротехнический университет  
«ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия  
rustamovna.a3@gmail.com

**Аннотация.** Исследуются возможности применения методов искусственного интеллекта, в частности обучения с подкреплением, для акустической диагностики автономных систем. Предложены три алгоритма: алгоритм на основе глубоких нейронных сетей, многоагентный ансамблевый алгоритм и динамически адаптируемый ансамбль с генеративным усилением на основе генеративно-сопоставительной сети. Проведен сравнительный анализ их эффективности по критериям точности, устойчивости к шуму и требований к вычислительным ресурсам. Результаты показывают, что комбинированный подход с использованием обучения с подкреплением и генеративно-сопоставительной сети демонстрирует наивысшую точность (до 94.2 %) и адаптивность к изменяющимся условиям, что делает его перспективным для внедрения в промышленные системы реального времени. Сравнение методов проведено по трем критериям: точность диагностики, устойчивость к шуму и требования к вычислительным ресурсам. Результаты показали, что многоагентный алгоритм лучше всего справляется с анализом сигналов в условиях высокой зашумленности, а динамический ансамбль с GAN обеспечивает максимальную точность распознавания неисправностей (до 94.2 %) и способность адаптироваться к ранее неизвестным ситуациям. При этом метод на основе RL отличается низкими затратами ресурсов и минимальным временем отклика, что делает его удобным для систем с ограниченными вычислительными возможностями. Предложенные решения могут быть использованы для разработки практических систем предиктивного обслуживания, которые позволяют выявлять неисправности на ранних стадиях и поддерживать бесперебойную работу оборудования.

**Ключевые слова:** акустическая диагностика, обучение с подкреплением, искусственный интеллект, промышленное оборудование, генеративно-сопоставительные сети

**Для цитирования:** Салиева А. Р. О применении технологий искусственного интеллекта в задачах акустического распознавания // Изв. СПбГЭТУ «ЛЭТИ». 2026. Т. 19, № 2. С. 84–98. doi: 10.32603/2071-8985-2026-19-2-84-98.

Scientific article

## On the Application of Artificial Intelligence Technologies in Acoustic Recognition Tasks

**A. R. Salieva**

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia  
rustamovna.a3@gmail.com

**Abstract.** The possibilities of using artificial intelligence methods, in particular reinforcement learning, for acoustic diagnostics of autonomous systems are being investigated. Three algorithms are proposed: algorithm based on deep neural networks, multi-agent ensemble algorithm and dynamically adaptable ensemble with generative reinforcement based on generative-adversarial network. A comparative analysis of their effectiveness was carried out according to the criteria of accuracy, noise resistance, and computing resource requirements. The results show that the combined approach using reinforcement learning and a generative-adversarial network demonstrates the highest accuracy (up to 94.2 %) and adaptability to changing conditions,

which makes it promising for implementation in real-time industrial systems. The methods were compared according to three criteria: diagnostic accuracy, noise tolerance, and computing resource requirements. The results showed that the multi-agent algorithm copes best with signal analysis in high-noise environments, and the dynamic ensemble with GAN provides maximum error recognition accuracy (up to 94.2 %) and the ability to adapt to previously unknown situations. At the same time, the RL-based method is characterized by low resource costs and minimal response time, which makes it convenient for systems with limited computing capabilities. The proposed solutions can be used to develop practical predictive maintenance systems that can detect malfunctions at an early stage and maintain trouble-free operation of equipment.

**Keywords:** acoustic diagnostics, reinforcement learning, artificial intelligence, industrial equipment, generative adversarial networks

**For citation:** Salieva A. R. On the Application of Artificial Intelligence Technologies in Acoustic Recognition Tasks // LETI Transactions on Electrical Engineering & Computer Science. 2026. Vol. 19, no. 2. P. 84–98. doi: 10.32603/2071-8985-2026-19-2-84-98.

**Введение.** Цифровизация промышленного производства проявляется во внедрении автономных и роботизированных систем, функционирующих при минимальном участии человека. В подобных условиях критически важным становится обеспечение надежности оборудования: отказ даже одного узла может привести к остановке технологической линии, существенным экономическим потерям и угрозе безопасности персонала [1]–[3].

Традиционные методы диагностики: регламентное обслуживание, визуальный осмотр, а также спектральный, вейвлет- и статистический анализ виброакустических сигналов обладают рядом ограничений. Во-первых, они характеризуются низкой адаптивностью и зависят от квалификации персонала. Во-вторых, их эффективность резко снижается в условиях производственного шума и при слабовыраженных или нетипичных дефектах [4], [5]. Эти факторы ограничивают применение классических методов для предиктивного обслуживания в динамично меняющихся эксплуатационных условиях.

Перспективной альтернативой традиционным методам служит акустическая диагностика, основанная на анализе звуковых сигналов, возникающих в процессе работы механизмов. Звуковые сигналы содержат информацию о трении, резонансах, ударах и других механических процессах. В отличие от вибродиагностики, акустические методы могут реализовываться бесконтактно, что особенно важно при ограниченном доступе к оборудованию [6]–[8]. Однако эффективность таких методов напрямую зависит от устойчивости алгоритмов анализа к шумам и изменению режимов эксплуатации.

В этих условиях особую актуальность приобретают методы искусственного интеллекта, и прежде всего обучение с подкреплением (Reinfor-

cement Learning, RL). В то время как традиционные алгоритмы машинного обучения, требуют значительных объемов размеченных данных и плохо адаптируются к новым условиям, RL позволяет строить модели, обучающиеся на взаимодействиях с окружающей средой и самостоятельно корректирующие диагностическую стратегию [9], [10]. Такой подход обеспечивает гибкость, самообучаемость и устойчивость к ранее неизвестным типам неисправностей.

Научная задача настоящего исследования заключается в разработке архитектур и алгоритмов интеллектуальной акустической диагностики на основе RL, способных:

- обучаться на несбалансированных и неполных данных;
- адаптироваться к изменяющейся шумовой среде;
- учитывать контекст функционирования оборудования;
- обеспечивать интерпретируемость и предсказуемость работы системы.

Цель исследования – разработка методов и алгоритмов интеллектуальной акустической диагностики технического состояния автономного оборудования на основе обучения с подкреплением. Объектом исследования выступают интеллектуальные системы диагностики промышленного оборудования, использующие акустические сигналы как основной источник информации, а предметом – алгоритмы обработки, анализа и классификации акустических сигналов с применением RL и ансамблевых методов.

В работе применялся комплекс методов:

- глубокое обучение: сверточные нейронные сети (Convolutional Neural Network, CNN), рекуррентные нейронные сети (Recurrent Neural Network, RNN), нейронная долгая краткосрочная па-

мья (Long Short-Term Memory, LSTM) для извлечения признаков и классификации [11];

– генеративные модели: генеративно-состязательная сеть (Generative adversarial network, GAN для генерации синтетических данных редких отказов;

– обучение с подкреплением (глубокая Q-сеть – Deep Q-Network, DQN, проксимальная политика оптимизация – Proximal Policy Optimization, PPO) для адаптивного управления диагностикой;

– ансамблевые модели на основе интеграции экспертных агентов [12].

**Анализ существующих подходов к решению задач акустической диагностики.** Акустическая диагностика технического состояния оборудования – важный элемент предиктивного обслуживания современных производственных систем. Она особенно востребована в условиях ограниченного доступа к узлам оборудования и невозможности остановки технологического процесса для проведения регламентных проверок.

Существующие подходы к решению задач акустической диагностики можно условно разделить на три группы:

1. Традиционные аналитические методы обработки сигналов.

2. Методы машинного обучения (Machine Learning, ML).

3. Методы обучения с подкреплением.

Последняя категория представляет собой относительно новое направление, демонстрирующее перспективные результаты в условиях динамически изменяющейся акустической среды.

1. *Традиционные аналитические методы.* Классические методы анализа сигналов не предполагают использования обучающих выборок и опираются на априорные математические модели:

– *спектральный анализ (Fast Fourier Transform, FFT) [13], [14]* применяется для выделения гармонических составляющих и характерных частот неисправностей. Однако данный метод демонстрирует низкую эффективность при изменении режимов работы оборудования и в условиях наложения шумов;

– *вейвлет-преобразования [15], [16]* обеспечивают локализацию признаков во временной и частотной областях, что повышает вероятность обнаружения кратковременных аномалий. Вместе с тем необходимость точного выбора базисной функции и масштабов существенно осложняет автоматизацию применения метода;

– *статистический анализ временных рядов [17]*, включающий вычисление среднеквадратическое значение, дисперсии, коэффициента асимметрии и эксцесса, используется для выявления отклонений в характеристиках сигнала. Ограничивает данный подход высокая чувствительность показателей к шуму и неоднозначность классификации дефектов.

Таким образом, несмотря на простоту реализации и интерпретируемость, традиционные методы недостаточно эффективны при эксплуатации оборудования в сложной акустической среде.

2. *Методы машинного обучения.* В отличие от аналитических подходов, методы ML позволяют автоматически извлекать информативные признаки из сигналов, что повышает устойчивость к шуму и снижает зависимость от ручной настройки параметров:

– *метод опорных векторов (Support Vector Machine, SVM) [18]* эффективен при небольшом числе признаков и высокой размерности пространства. Основным ограничением служит необходимость подбора функции ядра и низкая масштабируемость при увеличении объемов данных.

– *случайный лес (Random Forest) [19]* обладает высокой обобщающей способностью и устойчивостью к шумам. Однако при наличии неконсистентных аннотаций данных алгоритм подвержен переобучению.

– *сверточные и рекуррентные нейронные сети (CNN, RNN, LSTM) [20]–[22]* продемонстрировали высокую эффективность в задачах классификации акустических сигналов и анализа последовательностей. Основные недостатки заключаются в высокой вычислительной ресурсоемкости и значительной длительности обучения.

Обобщенная оценка существующих подходов к решению задач акустической диагностики представлена в табл. 1 и 2, где описаны ограничения методов (табл. 1), их достоинства и недостатки (табл. 2).

Как видно из табл. 1, существующие методы акустической диагностики обладают ограничениями, связанными с требованиями к качеству исходных данных и к вычислительным ресурсам. Традиционные алгоритмы оказываются недостаточно устойчивыми в условиях шума, а методы машинного обучения демонстрируют зависимость от больших размеченных выборок и низкую адаптивность при изменении условий эксплуатации.

В табл. 2 показано, что, несмотря на очевидные достоинства каждого класса методов – от простоты реализации и интерпретируемости тра-

Табл. 1. Ограничения существующих подходов к решению задач акустической диагностики  
 Tab. 1. Limitations of existing approaches to solving problems of acoustic diagnostics

Подходы/методы	Ограничение	Пояснение
SVM, Random Forest, CNN	Снижение точности диагностики при низком преобразовании звука (60–75 %)	Искажение признаков приводит к росту числа ложноположительных и ложноотрицательных классификаций [15]
Все методы ML	Зависимость от размеченных наборов данных	В реальных условиях объем экспертно аннотированных акустических событий ограничен, что снижает эффективность обучения
SVM, Random Forest	Низкая адаптивность	Требуется повторное обучение модели при поступлении новых данных
CNN, LSTM	Высокая вычислительная сложность	Для работы в реальном времени необходимы графическим процессором при их отсутствии увеличивается время отклика системы

Табл. 2. Достоинства и недостатки подходов/методов к решению задач акустической диагностики  
 Tab. 2. Advantages and disadvantages of approaches/methods to solving problems of acoustic diagnostics

Подходы/методы	Достоинства	Недостатки
Традиционные (FFT, вейвлет, статистика)	Простота реализации, интерпретируемость, низкие требования к вычислительным ресурсам	Низкая адаптивность, ограниченная точность в условиях шума, низкая эффективность при сложных дефектах
ML (SVM, Random Forest)	Автоматическое выделение признаков, устойчивость к шуму, выше точность по сравнению с традиционными методами	Зависимость от размеченных наборов данных, слабая адаптивность, переобучение при изменении условий
ML (CNN, LSTM)	Высокая точность в стабильных условиях, способность анализировать сложные сигналы	Высокая ресурсоемкость, низкая интерпретируемость, длительный процесс обучения

диционных алгоритмов до высокой точности нейросетевых моделей, – все подходы имеют свои недостатки. Это ограничивает их применение в реальных промышленных условиях, где важны как надежность, так и возможность работы в реальном времени.

**Применение технологий искусственного интеллекта в задачах акустического распознавания в различных сферах.** С задачами акустического распознавания можно встретиться во многих областях человеческой деятельности, и для их решения сегодня активно и успешно применяются технологии искусственного интеллекта. Это, например, следующие сферы деятельности:

*Медицина.* CNN и LSTM используются для анализа дыхательных и сердечных шумов, обеспечивая выявление патологий даже при высоком уровне фоновых шумов [23], [24].

*Системы безопасности.* Глубокие сети и трансформеры применяются для классификации выстрелов, криков и звуков разрушения в шумной городской среде, что требует высокой точности и минимальных задержек [25].

*Автомобильная индустрия.* Алгоритмы ML используются для мониторинга состояния двигателей и трансмиссий, включая выявление износа подшипников и зубчатых передач в реальном времени.

*Энергетика.* Акустический контроль применяется для раннего обнаружения повреждений в

газотурбинных установках и ветряных турбинах, что снижает эксплуатационные риски и затраты.

*Робототехника.* В автономных системах акустический анализ используется для диагностики механизмов и локализации источников звука, что повышает надежность и адаптивность оборудования.

Наработанный опыт применения методов искусственного интеллекта в задачах акустического распознавания в различных областях деятельности подтверждает их потенциал и в области промышленной диагностики. Вышеприведенные примеры демонстрируют, что акустические модели, обученные в смежных областях, могут быть адаптированы для промышленной диагностики с учетом специфики производственного шума.

**Архитектура системы акустического распознавания.** С учетом ограничений методов традиционных и машинного обучения особое внимание привлекают три направления, которые позволяют преодолеть выявленные барьеры: обучение с подкреплением, многоагентные ансамблевые подходы и гибридные решения, сочетающие RL с ансамблями и генеративными моделями. Были исследованы возможности всех трех направлений.

Разработана архитектура системы акустического распознавания неисправностей оборудования. На рис. 1 представлена диаграмма использования предлагаемой системы.

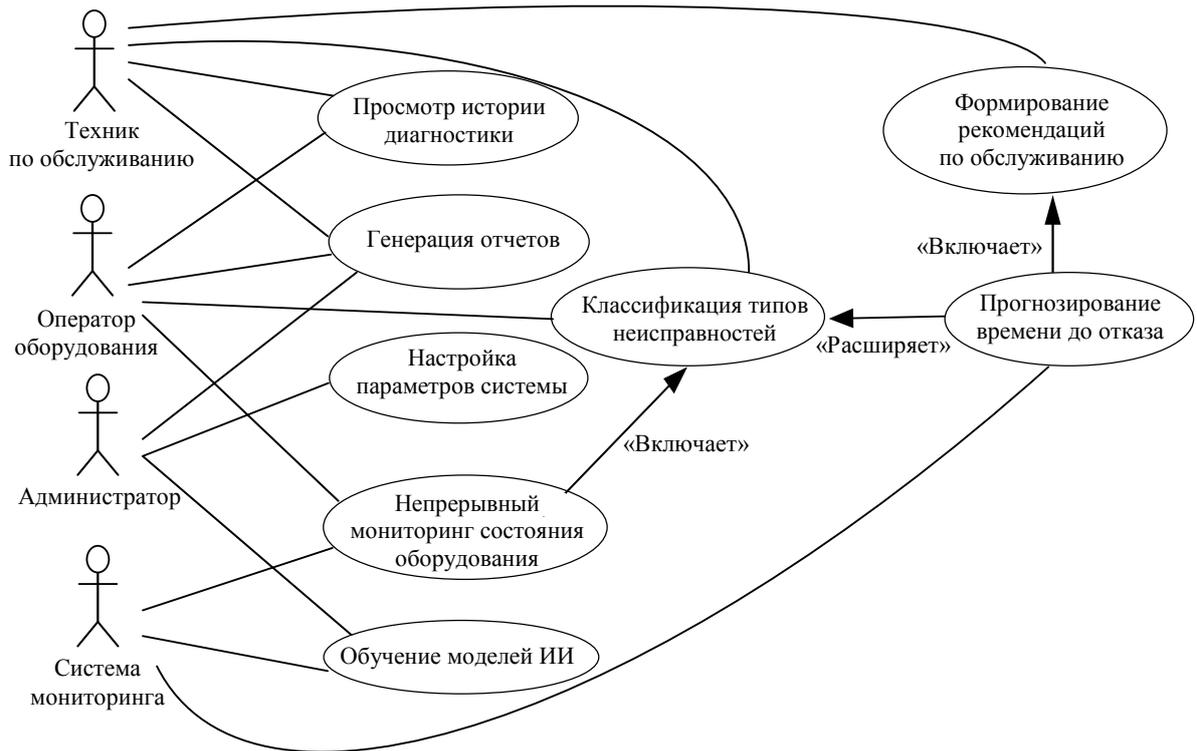


Рис. 1. Диаграмма вариантов использования системы  
 Fig. 1. Diagram of system use cases

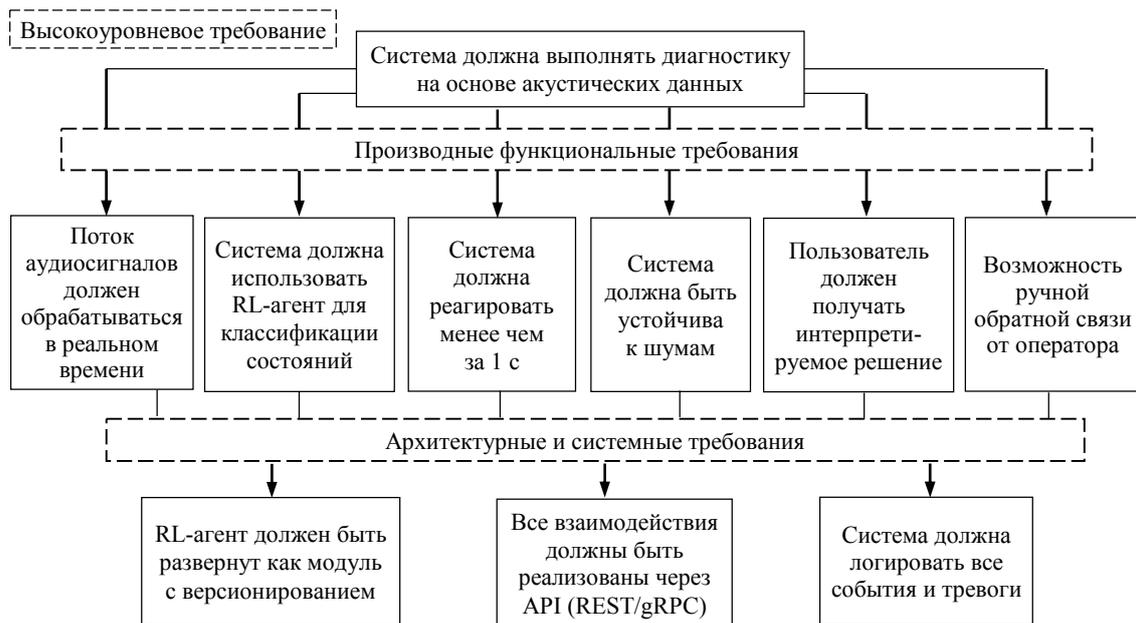


Рис. 2. Диаграмма требований системы акустического распознавания неисправности оборудования  
 Fig. 2. Diagram of the requirements of the acoustic equipment fault detection system

Диаграмма отражает взаимодействие основных категорий пользователей (техник по обслуживанию, оператор оборудования, администратор системы) с функциональными компонентами системы и демонстрирует взаимосвязь между ключевыми задачами диагностики: классификацией неисправностей, прогнозированием времени до отказа, формированием отчетности и обучением моделей.

По результатам анализа предметной области, а именно, требований к процессу диагностики неисправностей на основе акустического распознавания, была сформирована диаграмма требований к системе (рис. 2), диаграмма последовательности (рис. 3) и ER-диаграмма (рис. 4).

Диаграмма требований (рис. 2) иллюстрирует взаимосвязь высокоуровневых, функциональных

и системных требований к разрабатываемой системе акустического распознавания неисправностей оборудования.

Диаграмма последовательности (рис. 3) показывает процесс обработки акустического сигнала – от его поступления с датчика до выявления неисправности и уведомления оператора.

ER-диаграмма (рис. 4) показывает модель данных, используемую для хранения информации об акустических сигналах, выявленных неисправностях и взаимодействии компонентов системы диагностики технического оборудования. Модель включает девять основных сущностей: ACOUSTIC\_SIGNAL (центральная сущность для хранения акустических данных), SENSOR (информация о датчиках и их характеристиках), EQUIPMENT (данные о техническом оборудовании), FEATURES (извлеченные признаки сигналов для анализа), DIAGNOSIS (результаты диагностического анализа неисправностей), TRAINING\_DATA (обучающие данные для моделей машинного обучения), SYSTEM\_PERFORMANCE (метрики производительности системы), AI\_AGENT (характеристики используемых моделей искусственного интеллекта) и MAINTENANCE\_HISTORY (история технического обслуживания оборудования). Данная архитектура обеспечивает полный цикл обработки данных от сбора акустических сигналов до диагностики неисправностей и оценки эффективности системы.

**Структура и программные компоненты системы акустической диагностики.** Физическая структура системы формируется из интегрированного комплекса сенсорных модулей, высокоскоростной телекоммуникационной инфраструктуры и центрального вычислительного блока, как показано на рис. 5. Основной элемент системы – комплекс акустического мониторинга (КАМ), включающий несколько микрофонных модулей. КАМ предназначен для регистрации акустических сигналов, производимых подвижными или изнашивающимися компонентами оборудования. В общем случае в системе может осуществляться мониторинг состояния нескольких узлов/агрегатов промышленного оборудования (например, это может быть турбокомпрессорная установка с газотурбинным приводом, система главных циркуляционных насосов энергоблока АЭС или роторная дробилка в составе технологической линии горно-обогательного комбината), каждому из которых будет соответствовать свой КАМ [26], [27].

*Аппаратная часть системы.* Регистрация звуковых сигналов, издаваемых оборудованием, осуществляется с использованием пьезоэлектрических преобразователей, способных фиксировать высокочастотные компоненты акустической эмиссии до 80 кГц с чувствительностью не менее 35 мВ/Па. Преобразованные звуковые колебания усиливаются согласующими усилителями с полосовой фильтрацией и преобразуются в цифровой формат посредством аналого-цифровых преобразователей с частотой дискретизации не менее 200 кГц и разрядностью 24 бит, что позволяет обеспечивать точную фиксацию как спектральных, так и временных характеристик сигналов.

Микрофонные модули размещаются в зонах оборудования с наибольшей акустической информативностью, включая подшипниковые опоры, соединения и сварные швы трубопроводов, клапанные механизмы, насосы и компрессоры. Локальная предобработка данных включает нормализацию амплитуды, фильтрацию шумов, синхронизацию сигналов по времени и разбиение на фрагменты, что снижает нагрузку на сеть и повышает точность последующего анализа. В случае выявления аномальных сигналов, например резкого увеличения амплитуды на критических частотах, формируется приоритетный пакет данных, передаваемый в центральный процессорный блок [28], [29].

Передача данных между модулями и центральным сервером осуществляется по высокоскоростной шине EtherCAT с детерминированным временем доставки, не превышающим 100 мкс. Использование протокола Precision Time Protocol обеспечивает временную когерентность и точность триангуляции сигналов с разных модулей. Для повышения надежности предусмотрена топологическая избыточность сети с резервированием критических сегментов, а также защита от электромагнитных помех в соответствии со стандартом IEC 61000-4. В удаленных или труднодоступных зонах применяются беспроводные технологии передачи данных, обеспечивающие гибкость размещения сенсорных модулей.

Центральный процессорный блок выполняет агрегацию и анализ поступающих данных. Он реализует спектральный, кепстральный и вейвлет-анализ сигналов, извлечение диагностических признаков и их классификацию с использованием многоагентных ансамблевых алгоритмов машинного обучения. Сервер обеспечивает управление параметрами системы, логирование событий и визуализацию данных для оператора, а также интеграцию с корпоративными системами

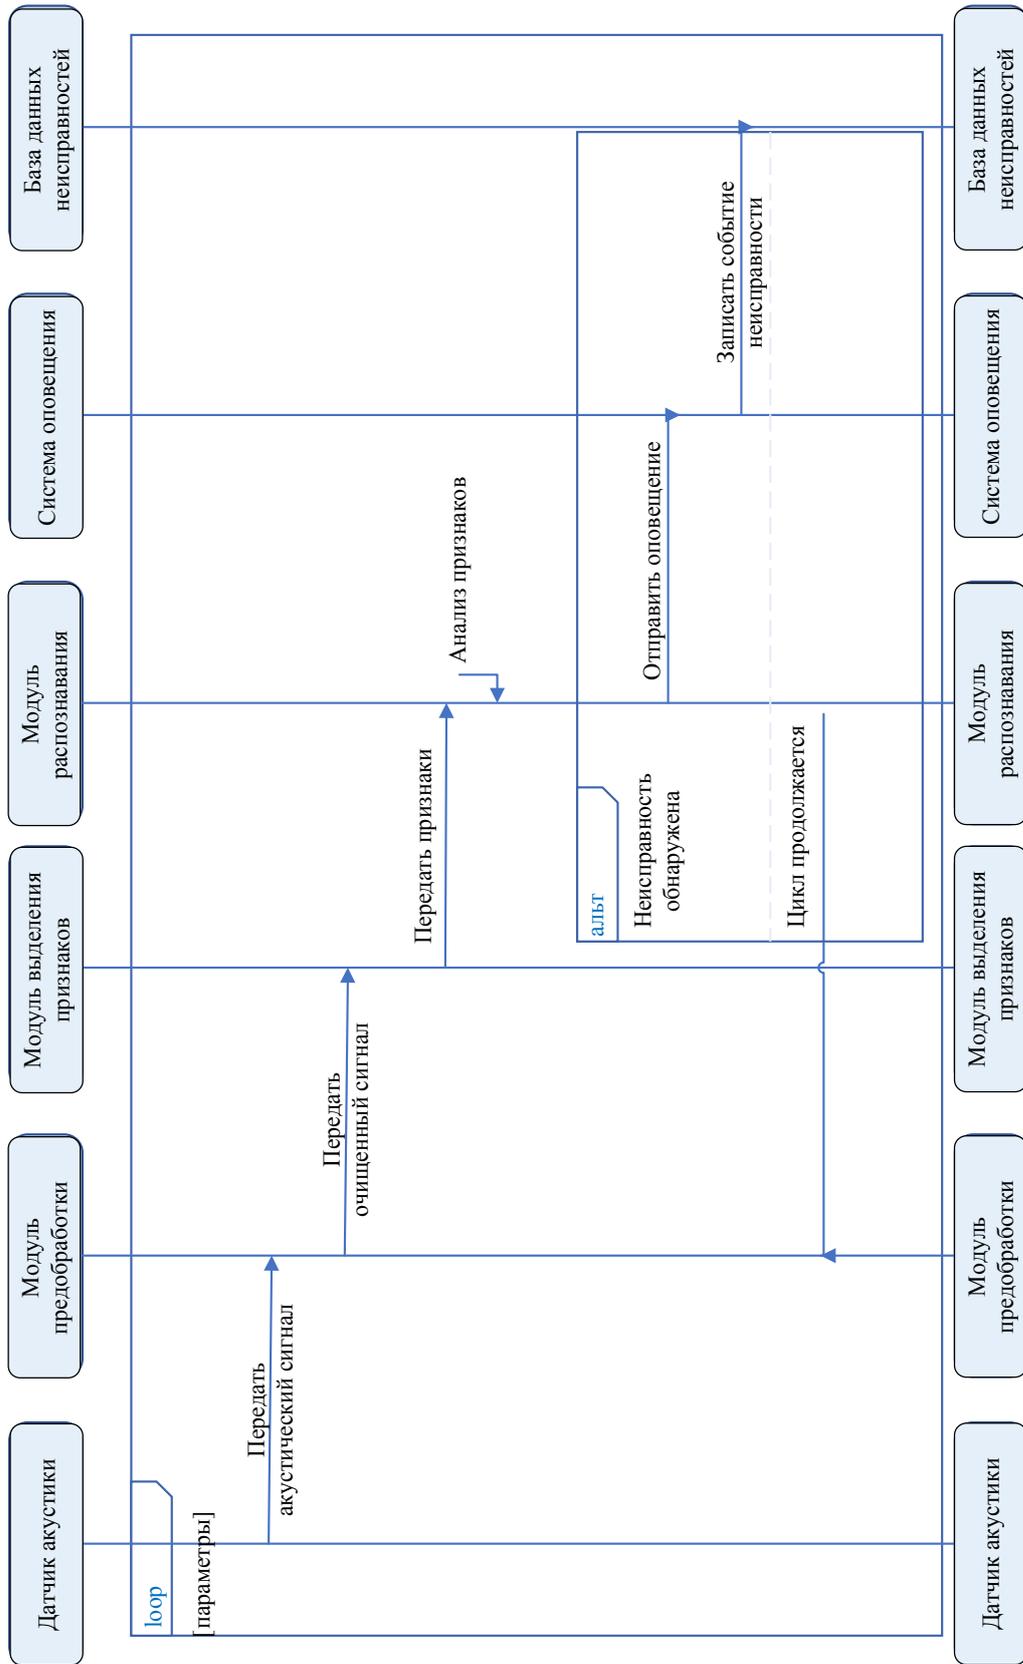


Рис. 3. Диаграмма последовательности системы акустического распознавания  
 Fig. 3. Sequence diagram of the acoustic equipment fault recognition system

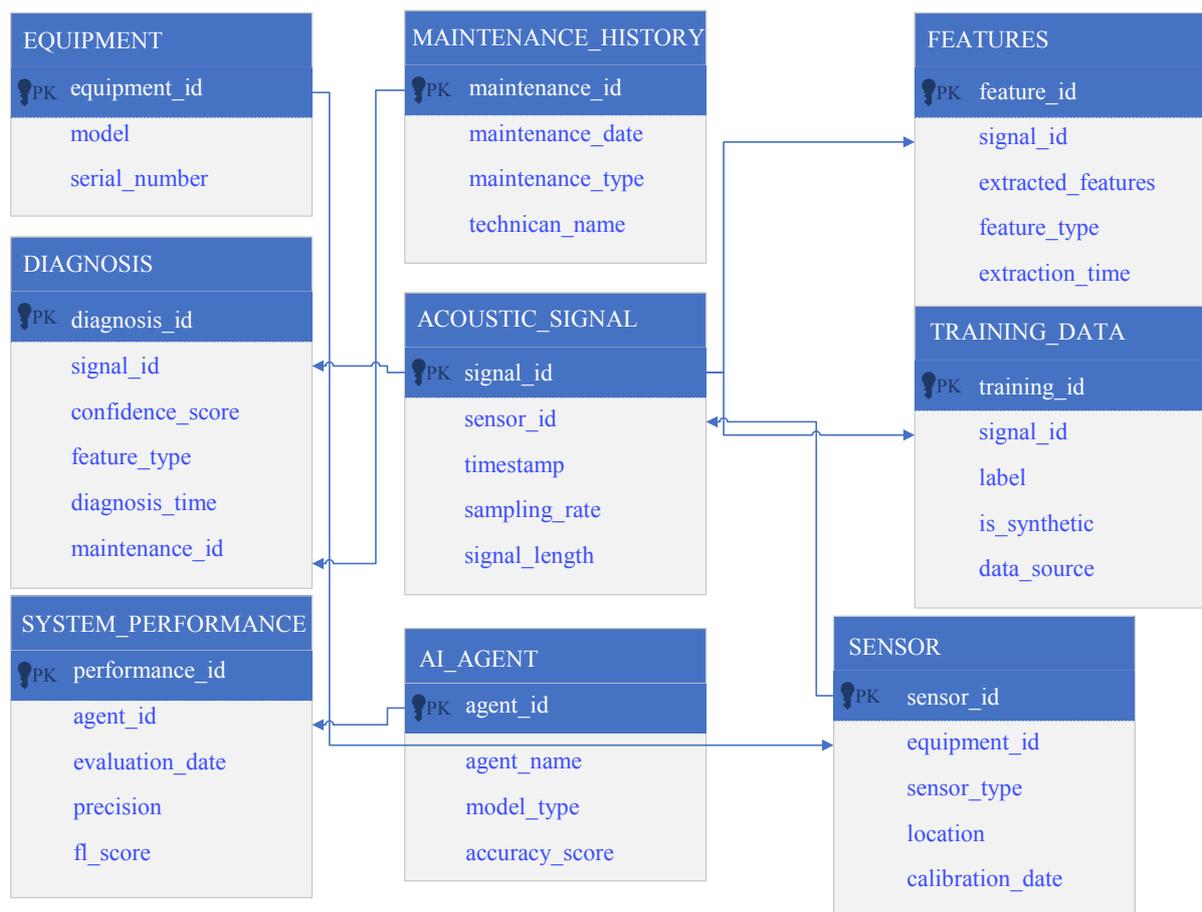


Рис. 4. ER-диаграмма (модели данных) системы акустического распознавания неисправности оборудования  
 Fig. 4. ER diagram (data models) of the acoustic equipment fault recognition system

управления предприятием (Enterprise Resource Planning, ERP) – планирование ресурсов предприятия; CMMS (Computerized Maintenance Management System) – компьютеризированная система управления техническим обслуживанием и ремонтами; SCADA (Supervisory Control And Data Acquisition) – диспетчерское управление и сбор данных) через стандартные протоколы OPC UA (Open Platform Communications Unified Architecture) единая архитектура открытых платформ связи и протокол MODBUS (такая архитектура позволяет формировать масштабируемую, отказоустойчивую систему, способную работать в условиях высокой технологической нагрузки и агрессивной среды).

*Программно-алгоритмическое обеспечение системы.* Программное обеспечение системы реализует функции первичной фильтрации и декомпозиции сигналов, выделения диагностических признаков и классификации паттернов. Местная обработка в микропроцессорных блоках микрофонных модулей позволяет снизить объем передаваемых данных за счет алгоритмической компрессии и активировать режим повышенной дискретизации при выявлении отклонений. На

уровне центрального сервера реализуются механизмы выявления аномалий, прогнозирования остаточного ресурса и построения моделей предиктивного обслуживания. Использование ансамблевых алгоритмов на предобработанных в реальном времени сигналах повышает точность диагностики, обеспечивая раннее выявление дефектов, включая микротрещины в сварных швах, кавитационные процессы в насосных агрегатах и износ подшипников.

Формализация задачи в рамках RL-подхода обеспечивает возможность построения самообучающихся диагностических систем, которые способны адаптироваться к изменяющимся условиям эксплуатации оборудования, появлению новых типов дефектов и эволюции акустических характеристик в процессе износа механизмов.

Таким образом, представленная архитектура системы обеспечивает целостность сбора, синхронизации и предварительной обработки акустических данных, а также создает основу для последующего применения методов интеллектуального анализа. Ключевым этапом служит выбор и исследование алгоритмов распознавания, от которых



Рис. 5. Физическая структура системы акустического распознавания  
Fig. 5. The physical structure of the acoustic recognition system

зависят точность диагностики и адаптивность системы к изменяющимся условиям эксплуатации. В настоящей статье рассмотрены и сопоставлены несколько подходов к решению задачи акустического распознавания неисправностей, для которых были разработаны и протестированы соответствующие программные реализации.

**Сравнение алгоритмов акустического распознавания.** Для решения задач акустического распознавания неисправностей в работе промышленного оборудования было предложено 3 алгоритма [31]–[33] и разработаны соответствующие программные продукты [34], [35].

1. *RL-алгоритм классификации акустических сигналов.* Обучение с подкреплением представляет собой подход, при котором агент взаимодействует со средой и последовательно корректирует стратегию на основе сигналов награды. Общая схема диагностики для этого алгоритма показана на рис. 6. В рассматриваемой задаче агент реализован в виде нейронной сети, которая классифицирует акустические сигналы и определяет текущее состояние оборудования. Каждый акустический фрагмент преобразуется в вектор признаков, включающий мел-частотные кепстральные коэффициенты и спектральные характеристики. На основании этих признаков агент выбирает действие – например, классификацию состояния как «норма» или «дефект». Награда формируется с учетом точности предсказания и задержки выявления неисправности, что стимулирует своевременное обнаружение дефектов. Обновление стратегии осуществляется через функцию временного различия, позволяющую агенту постепенно по-

вышать качество решений. Ключевыми преимуществами данного метода служит высокая скорость отклика и компактность модели, что делает его пригодным для систем с ограниченными ресурсами. Однако алгоритм предъявляет повышенные требования к качеству функции награды и демонстрирует ограниченную устойчивость при работе с зашумленными сигналами [21].

2. *Многоагентный ансамблевый классификатор* представляет собой архитектуру, в которой несколько специализированных агентов обрабатывают сигнал параллельно. Общая схема алгоритма диагностики MAAR (многоагентный ансамблевый алгоритм распознавания) показана на рис. 7. Один агент анализирует спектрограмму с помощью CNN, другой работает с временными признаками на базе LSTM, третий учитывает контекст режима эксплуатации оборудования, а четвертый компенсирует влияние фонового шума. Результаты их классификаций агрегируются с использованием механизма взвешенного голосования. Такой подход обеспечивает высокую устойчивость к шуму и эффективность при работе даже на процессорах общего назначения, что делает его практически применимым в условиях ограниченных вычислительных ресурсов. Вместе с тем статическая конфигурация ансамбля приводит к снижению гибкости: веса агентов фиксируются после обучения, вследствие чего система хуже адаптируется к новым типам неисправностей и изменяющимся условиям эксплуатации [22].

3. *Динамически адаптируемый ансамбль с генеративным усилением* (схема его работы представлена на рис. 8) – наиболее комплексное решение.

Он сочетает преимущества RL и ансамблевого анализа, а также использует генеративно-сопоставительные сети (WaveGAN) для синтеза дополнительных данных, включая редкие и труднодоступные классы неисправностей. Обучение агентов ведется на расширенных датасетах, что позволяет повысить полноту охвата сценариев эксплуатации. Управление весами агентов осу-

ществляется через контроллер на основе RL, динамически перенастраивающий конфигурацию ансамбля в зависимости от текущего состояния акустической среды. В результате система демонстрирует максимальную точность классификации и высокую адаптивность даже в условиях сильных шумов. Однако данные достоинства достигаются ценой высокой вычислительной ресурсо-

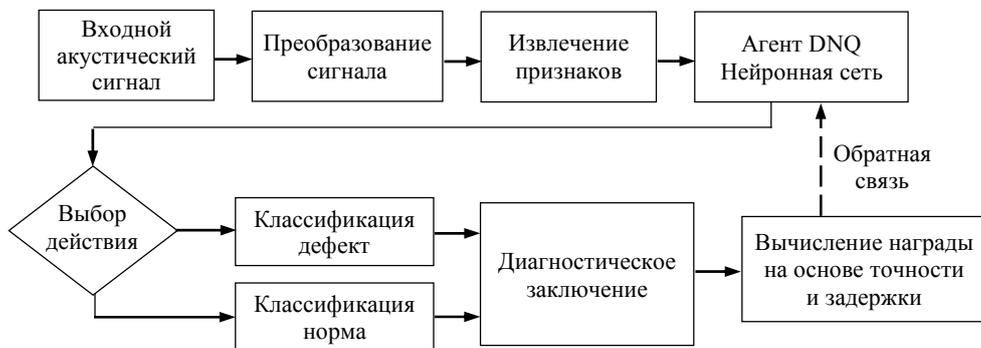


Рис. 6. Архитектура RL-алгоритма  
Fig. 6. Architecture of the RL algorithm

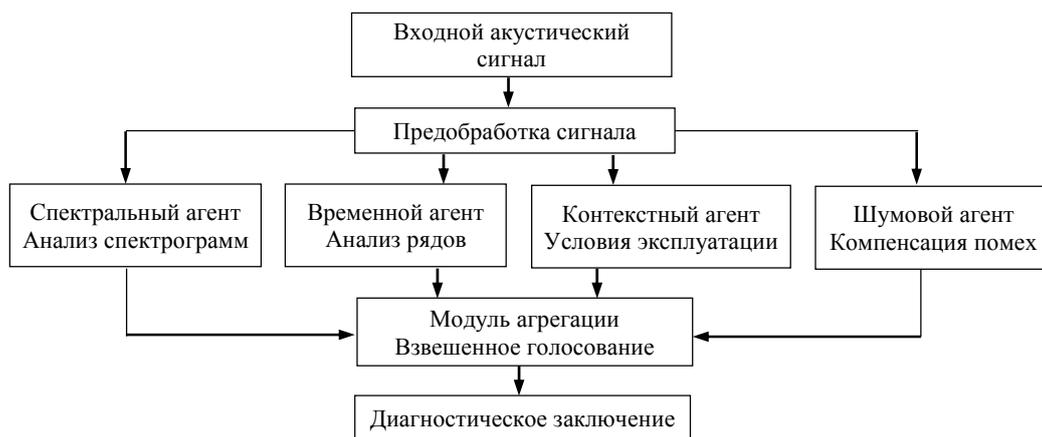


Рис. 7. Архитектура многоагентного ансамблевого алгоритма акустического распознавания  
Fig. 7. Architecture of a multi-agent ensemble acoustic recognition algorithm

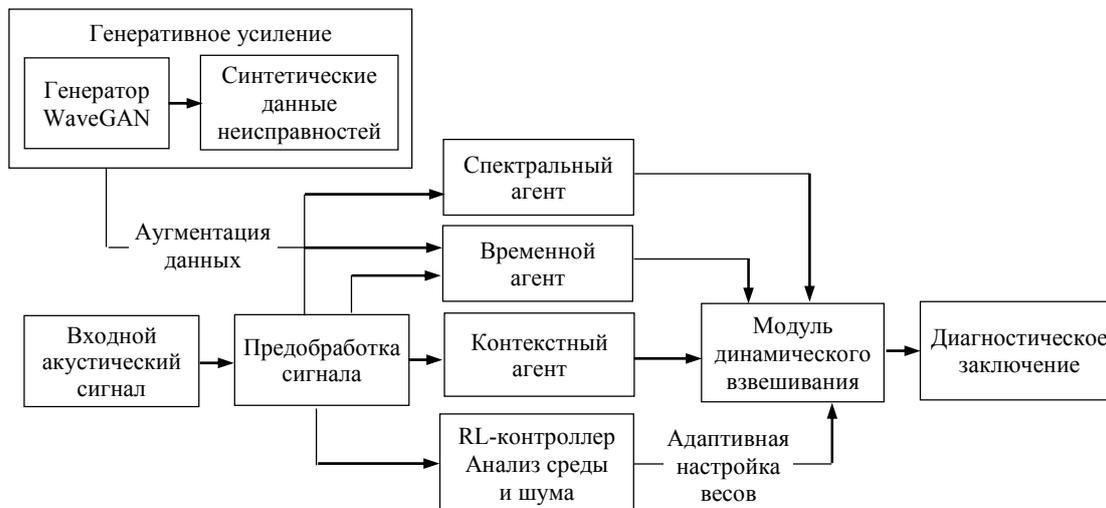


Рис. 8. Архитектура динамически адаптируемого ансамбля с генеративным усилением  
Fig. 8. Architecture of a dynamically adaptable ensemble with generative amplification

Табл. 3. Сравнительный анализ алгоритмов  
Tab. 3. Comparative analysis of algorithms

Показатель	RL-алгоритм	MAAR	Динамически адаптируемый ансамбль с генеративным усилением
Подход	Один агент (DQN)	Несколько агентов (CNN, RNN)	Ансамбль + GAN + RL
Тип агрегации	Отсутствует	Взвешенное голосование	Адаптивное голосование (DQN)
Устойчивость к шуму	Средняя	Высокая	Высокая
Точность	Средняя	Высокая	Максимальная
Затраты ресурсов	Низкие (CPU, ~150 Мбайт)	Средние (CPU, ~450 Мбайт)	Высокие (GPU, ~1.5 Гбайт)
Скорость работы	~0.25 с	~0.2 с	~0.45 с
Гибкость	Средняя (через $r$ )	Низкая (фиксированные веса)	Высокая (динамические веса, GAN)
Достоинства	Максимальная адаптивность, способность к самообучению, высокая точность	Устойчивость к шуму, возможность объединять разные типы признаков	Адаптивность, обучение без разметки, устойчивость к новым неисправностям
Недостатки	Высокие требования к ресурсам, сложность реализации	Сложность настройки весов агентов, статичность конфигурации	Длительное обучение, высокая потребность в данных взаимодействия
Способы снижения влияния недостатков	Оптимизация архитектуры, распределенная обработка, сокращение размерности признаков	Динамическая перенастройка весов, автоматический выбор состава агентов	Использование симуляторов, метод «безопасного исследования» (safe exploration), предварительное обучение на синтетических данных

емкости: работа модели требует до 1.5 Гбайт оперативной памяти и графического процессора, а сложность реализации возрастает вследствие интеграции нескольких архитектур [22].

Все разработанные алгоритмы прошли апробацию на экспериментальных данных промышленного оборудования. Проведенные исследования показали, что предложенные методы демонстрируют высокую точность акустического распознавания неисправностей при различной вычислительной нагрузке. В частности, RL-алгоритм обеспечивает минимальное время отклика и низкое потребление ресурсов, MAAR отличается устойчивостью к шумам, а динамический ансамбль показывает наилучшие значения метрик точности при наличии достаточной вычислительной мощности. Сравнительные характеристики алгоритмов сведены в табл. 3.

Проведенный сравнительный анализ показал, что каждый из рассмотренных алгоритмов обладает своими преимуществами и областью наибольшей эффективности. RL-алгоритм целесообразно использовать в системах с жесткими требованиями к быстродействию и ограниченными вычислительными ресурсами. MAAR демонстрирует устойчивость к шумам и хорошо подходит для эксплуатации в сложных акустических условиях. Динамический ансамбль обеспечивает

наивысшие показатели точности и универсальности, что делает его предпочтительным для критически важных объектов, где допустимы повышенные затраты ресурсов.

**Заключение.** В данной статье отражено исследование, посвященное применению технологий искусственного интеллекта, в частности обучения с подкреплением и генеративно-состязательных сетей, для задач акустической диагностики промышленного оборудования. Была обоснована актуальность перехода от традиционных методов анализа сигналов к самообучающимся и адаптивным системам, способным эффективно работать в условиях производственного шума и изменяющихся режимов эксплуатации.

В ходе работы была создана архитектура системы акустического распознавания, определены ее ключевые компоненты и функциональные требования. Предложены и реализованы три алгоритма: RL-алгоритм на основе DQN, многоагентный ансамблевый алгоритм и динамически адаптируемый ансамбль с генеративным усилением.

Проведенный сравнительный анализ показал, что каждый из алгоритмов имеет свою область эффективного применения. RL-алгоритм демонстрирует высокое быстродействие и низкое потребление ресурсов, что делает его пригодным для систем с жесткими ограничениями. MAAR

проявляет высокую устойчивость к шуму и эффективен в стабильных условиях. Наивысшую точность (до 94.2 %) и адаптивность к новым, в том числе редким, типам неисправностей показал динамически адаптируемый ансамбль с генеративным усилением, несмотря на его повышенную вычислительную сложность.

Практическая значимость исследований заключается в том, что разработанные алгоритмы и архитектурные решения позволяют создавать надежные

системы предиктивного обслуживания для критически важного промышленного оборудования, снижая риски незапланированных простоев и повышая общую эффективность производства.

Перспективы дальнейших исследований представляются в оптимизации вычислительной нагрузки гибридного алгоритма, разработке методов онлайн-обучения без полного перестроения модели, а также в более глубокой интеграции на основе реальных данных.

### Список литературы

- Zhang D., Lin Z., Gao Z. A novel fault detection with minimizing the noise-signal ratio using reinforcement learning // *Sensors*. 2018. Vol. 18, no. 9. Art. 3087. P. 1–20. doi: 10.3390/s18093087.
- Acoustic fault diagnosis method for rotating machinery based on collaborative perception information aggregation guidance network / Ch. Li, F. Zhang, Q. Wang, Yu. Han, T. Li, F. Teng, C. Yi, Y. Wu // *Intern. J. of Computational Intelligence Syst.* 2025. Vol. 18. Art. 150. P. 1–21. doi: 10.1007/s44196-025-00862-z.
- Ye T., Peng T., Yang L. Review on sound-based industrial predictive maintenance: from feature engineering to deep learning // *Math*. 2023. Vol. 13, no. 11. Art. 1724. P. 1–31. doi: 10.3390/math13111724.
- Problems of locating acoustic emission sources / Yu. G. Matvienko, I. E. Vasil'ev, D. V. Chernov, V. I. Ivanov, S. V. Elizarov // *Russ. J. of Nondestructive Testing*. 2021. Vol. 57. P. 769–778. doi: 10.1134/S1061830921090060.
- Lee J.-G., Kim K. S., Lee J. H. Sound-based unsupervised fault diagnosis of industrial equipment considering environmental noise // *Sensors*. 2024. Vol. 24, no. 22. Art. 7319. P. 1–35. doi: 10.3390/s24227319.
- Диагностика промышленного оборудования методом акустического контроля / А. С. Мартюгов, Е. В. Ершов, Л. Н. Виноградова, И. А. Варфоломеев // *Оптико-электронные приборы и устройства в системах распознавания образов и обработки изображений: матер. XVI междунар. науч.-техн. конф. «Распознавание – 2021», Курск: Юго-ЗапГУ, 2021. С. 172–174.*
- Ye L., Ma X., Wen C. Rotating machinery fault diagnosis method by combining time-frequency domain features and CNN knowledge transfer // *Sensors*. 2021. Vol. 21, no. 24. Art. 8168. doi: 10.3390/s21248168.
- Highly accurate machine fault diagnosis using deep transfer learning / S. Shao, S. McAleer, R. Yan, P. Baldi // *IEEE Trans. on Industrial Informatics*. 2019. Vol. 15, no. 4. P. 2446–2455. doi: 10.1109/TII.2018.2864759.
- Deep learning for diagnosis and classification of faults in industrial rotating machinery / R. M. Souza, E. G. S. Nascimento, U. A. Miranda, W. J. D. Silva, H. A. Lepikson // *Comp. & Industrial Engin.* 2021. Vol. 153. Art. 107060. P. 1–23. doi: 10.1016/j.cie.2020.107060.
- A novel RSG-based intelligent bearing fault diagnosis method for motors in a high-noise industrial environment / P. Lyu, K. Zhang, W. Yu, B. Wang, Ch. Liu // *Advanced Engin. Inform.* 2022. Vol. 52, no. 3. Art. 101564. doi: 10.1016/j.aei.2022.101564.
- Variational policy gradient method for reinforcement learning with general utilities / Ju. Zhang, A. S. Koppel, A. Bedi, C. Szepesvari, M. Wang // *Machine Learning*. 2020. P. 1–12. doi: 10.48550/arXiv.2007.02151.
- Deep reinforcement learning with spiking Q-learning / D. Chen, P. Peng, T. Huang, Y. Tian // *Comp. Sci. Neural and Evolutionary Comp.* 2022. P. 1–15. doi: 10.48550/arXiv.2201.09754.
- Review of current trends and uses of machine learning for discrete acoustic emission interpretation / M. Pénicaud, F. Lequien, C. Fisher, A. Recoquilly // *J. of Nondestructive Evaluation*. 2025. Vol. 44, no. 3. Art. 109. P. 1–23. doi: 10.1007/s10921-025-01247-0.
- Ciaburro G., Iannace G. Machine-learning-based methods for acoustic emission testing // *App. Sci.* 2022. Vol. 12, no. 20. Art. 10476. P. 1–30. doi: 10.3390/app122010476. URL: <https://encyclopedia.pub/entry/32514> (дата обращения: 15.09.2025).
- Wang Ch., Sun Y., Wang X. Image deep learning in fault diagnosis of mechanical equipment // *J. Intell. Manuf.* 2024. Vol. 35. P. 2475–2515. doi: 10.1007/s10845-023-02176-3.
- A new bearing fault diagnosis method based on modified convolutional neural networks / J. Zhang, Y. Sun, L. Guo, H. Gao, H. Xin, H. Song // *Chinese J. of Aeronautics*. 2020. Vol. 33, no. 2. P. 439–447. doi: 10.1016/j.cja.2019.07.011.
- Addison P. S. *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. Boca Raton: CRC Press, 2002. 368 p.
- Trustworthy clinical AI solutions: A unified review of uncertainty quantification in Deep Learning models for medical image analysis / B. Lambert, F. Forbes, S. Doyle, H. Dehaene, M. Dojat // *Artif Intell Med*. 2024. Vol. 150. P. 102830. doi: 10.1016/j.artmed.2024.102830. URL: <https://pubmed.ncbi.nlm.nih.gov/38553168> (дата обращения: 12.09.25).
- Bearing fault diagnosis based on improved convolutional deep BeliefNetwork / S. Liu, J. Xie, C. Shen, X. Shang, D. Wang, Z. Zhu // *Appl. Sci.* 2020. Vol. 10. P. 6359.

20. An improved random forest algorithm of fault diagnosis for rotating machinery / Z. Wang, M. Zhong, R. Yang, Y. Liu // Proc. 11<sup>th</sup> CAA Symp. on Fault Detection, Supervision, and Safety for Techn. Proc.: SAFEPROCESS 2019. Xiamen, China: IEEE, 2019. P. 12–17. doi: 10.1109/SAFEPROCESS45799.2019.9213389.

21. Wang C., Sun Y., Wang X. Image deep learning in fault diagnosis of mechanical equipment // J. of Intelligent Manufacturing. 2024. Vol. 35, no. 6. P. 2475–2515. doi: 10.1007/s10845-023-02176-3.

22. Noise-robust fault diagnosis method for rotating machinery based on hybrid-domain graph neural network and SGWT feature enhancement / X. Dong, L. Dong, Z. Liao, S. Liu, Z. Luo // SSRN. 2025. 26 p. doi: 10.2139/ssrn.5421600. URL: <https://ssrn.com/abstract=5421600> (дата обращения 15.09.2025).

23. Deep learning methods for heart sounds classification: A systematic review / W. Chen, Q. Sun, X. Chen, G. Xie, H. Wu, C. Xu // Entropy 2021. Vol. 23. P. 667. doi: 10.3390/e23060667 (дата обращения: 18.09.2025).

24. Combining visual and acoustic features for audio classification tasks / L. Nanni, Y. M. G. Costa, D. R. Lucio, C. N. Silla, S. Brahmam // Pattern Recognition Lett. 2017. Vol. 88. P. 49–56. doi: 10.1016/j.patrec.2017.01.013.

25. Signal processing for the condition-based maintenance of rotating machines via vibration analysis: a tutorial / O. Matania, L. Bachar, E. Bechhoefer, J. Bortman // Sensors. 2024. Vol. 24, no. 2. P. 454. doi: 10.3390/s24020454.

26. Ayad A., Bouffard F. Enabling system flexibility in smart grid architecture // IEEE Trans. on Engin. Management. 2025. Vol. 72. P. 1892–1908. doi: 10.1109/TEM.2025.3563779.

27. A review of machine learning and deep learning techniques for anomaly detection in IoT data / R. Al-amri, R. K. Murugesan, M. Man, A. F. Abdulateef, M. A. Al-Sharafi, A. A. Alkahtani // Appl. Sci. 2021. Vol. 11, no. 12. Art. 5320. P. 1–23. doi: 10.3390/app11125320.

28. Deep learning approaches for robust time of arrival estimation in acoustic emission monitoring / F. Zonzini, D. Bogomolov, T. Dhamija, N. Testoni, L. De Marchi, A. Marzani // Sensors. 2022. Vol. 22, no. 3. Art. 1091. doi: 10.3390/s22031091.

29. Митр Д. В. Классификация типов наземной техники по акустическому сигналу на основе алгоритма с временной кодировкой // Сб. докл. Всерос. науч.-техн. конф. «Студенческая научная весна: Машиностроительные технологии». М.: ООО «Квантор-Форм», 2023. С. 631–632. URL: [studvesna.ru/go=articles&id=3682](http://studvesna.ru/go=articles&id=3682) (дата обращения: 20.11.2025).

30. Cinar Z. M., Abdusselam R., Gencay E. Audio-based predictive maintenance system architecture // ResearchGate. 2022. URL: [https://www.researchgate.net/figure/Audio-Based-Predictive-Maintenance-System-Architecture-Cinar-et-al-2022\\_fig1\\_389781694](https://www.researchgate.net/figure/Audio-Based-Predictive-Maintenance-System-Architecture-Cinar-et-al-2022_fig1_389781694) (дата обращения: 27.06.2025).

31. Верзун Н. А., Колбанев М. О., Салиева А. Р. Многоагентный ансамблевый алгоритм акустического распознавания нарушений работоспособности автономного технологического оборудования // Информационно-управляющие системы. 2025. № 3. С. 14–24. doi: 10.31799/1684-8853-2025-3-14-24.

32. Верзун Н. А., Колбанев М. О., Салиева А. Р. Разработка и исследование метода обучения с подкреплением для акустической диагностики промышленного оборудования // Науч.-техн. вестн. ИТМО. 2025. Т. 25, № 5. С. 961–970. doi: 10.17586/2226-1494-2025-25-5-961-970.

33. Верзун Н. А., Колбанев М. О., Салиева А. Р. Адаптивная система распознавания по акустическим признакам на базе генеративно-состязательных сетей и обучения с подкреплением // Изв. СПбГЭТУ «ЛЭТИ». 2026. Т. 19, № 1. С. 15–35.

34. Свид. о гос. рег. программы для ЭВМ № 2025619237. Акустическая система диагностики неисправностей промышленного оборудования на основе обучения с подкреплением (АСД-ОП) / А. А. Бердникова, М. О. Колбанев, Н. А. Верзун, А. Р. Салиева. Правообладатель: Нижегор. ГИЭУ. 2025. Дата рег. 10.04.2025; опубли. 14.04.2025.

35. Свид. о гос. рег. программы для ЭВМ № 2025662662. Многоагентная ансамблевая программа акустического распознавания нарушений работоспособности автономного технологического оборудования (МААР) / А. Р. Салиева, М. О. Колбанев, Н. А. Верзун. Правообладатель: Нижегор. ГИЭУ. 2025. Дата рег. 13.05.2025; опубли. 22.05.2025.

---

#### Информация об авторе

**Салиева Аделина Рустамовна** – аспирант гр. 3933, кафедра «Информационные системы» СПбГЭТУ «ЛЭТИ».

E-mail: [rustamovna.a3@gmail.com](mailto:rustamovna.a3@gmail.com)

<https://orcid.org/0009-0001-9519-5773>

#### References

1. Zhang D., Lin Z., Gao Z. A novel fault detection with minimizing the noise-signal ratio using reinforcement learning // Sensors. 2018. Vol. 18, no. 9. Art. 3087. P. 1–20. doi: 10.3390/s18093087.

2. Acoustic fault diagnosis method for rotating machinery based on collaborative perception information ag-

gregation guidance network / Ch. Li, F. Zhang, Q. Wang, Yu. Han, T. Li, F. Teng, C. Yi, Y. Wu // Intern. J. of Computational Intelligence Syst. 2025. Vol. 18. Art. 150. P. 1–21. doi: 10.1007/s44196-025-00862-z.

3. Ye T., Peng T., Yang L. Review on sound-based industrial predictive maintenance: from feature engineer-

- ing to deep learning // *Math*. 2023. Vol. 13, no. 11. Art. 1724. P. 1–31. doi: 10.3390/math13111724.
4. Problems of locating acoustic emission sources / Yu. G. Matvienko, I. E. Vasil'ev, D. V. Chernov, V. I. Ivanov, S. V. Elizarov // *Russ. J. of Nondestructive Testing*. 2021. Vol. 57. P. 769–778. doi: 10.1134/S1061830921090060.
5. Lee J.-G., Kim K. S., Lee J. H. Sound-based unsupervised fault diagnosis of industrial equipment considering environmental noise // *Sensors*. 2024. Vol. 24, no. 22. Art. 7319. P. 1–35. doi: 10.3390/s24227319.
6. Diagnostika promyshlennogo oborudovanija metodom akusticheskogo kontrolja / A. S. Martyugov, E. V. Ershov, L. N. Vinogradova, I. A. Varfolomeev // *Optiko-elektronnye pribory i ustrojstva v sistemax raspoznavanija obrazov i obrabotki izobrazhenij: mat. XVI mezhdunar. nauch.-texn. konf. «Raspoznavanie – 2021»*, Kursk: Yugo-ZapGU, 2021. S. 172–174. (In Russ.).
7. Ye L., Ma X., Wen C. Rotating machinery fault diagnosis method by combining time-frequency domain features and CNN knowledge transfer // *Sensors*. 2021. Vol. 21, no. 24. Art. 8168. doi: 10.3390/s21248168.
8. Highly accurate machine fault diagnosis using deep transfer learning / S. Shao, S. McAleer, R. Yan, P. Baldi // *IEEE Trans. on Industrial Informatics*. 2019. Vol. 15, no. 4. P. 2446–2455. doi: 10.1109/TII.2018.2864759.
9. Deep learning for diagnosis and classification of faults in industrial rotating machinery / R. M. Souza, E. G. S. Nascimento, U. A. Miranda, W. J. D. Silva, H. A. Lepikson // *Comp. & Industrial Engin.* 2021. Vol. 153. Art. 107060. P. 1–23. doi: 10.1016/j.cie.2020.107060.
10. A novel RSG-based intelligent bearing fault diagnosis method for motors in a high-noise industrial environment / P. Lyu, K. Zhang, W. Yu, B. Wang, Ch. Liu // *Advanced Engin. Informatics*. 2022. Vol. 52, no. 3. Art. 101564. doi: 10.1016/j.aei.2022.101564.
11. Variational policy gradient method for reinforcement learning with general utilities / Ju. Zhang, A. S. Koppel, A. Bedi, C. Szepesvari, M. Wang // *Machine Learning*. 2020. P. 1–12. doi: 10.48550/arXiv.2007.02151.
12. Deep reinforcement learning with spiking Q-learning / D. Chen, P. Peng, T. Huang, Y. Tian // *Comp. Sci. Neural and Evolutionary Comp.* 2022. P. 1–15. doi: 10.48550/arXiv.2201.09754.
13. Review of current trends and uses of machine learning for discrete acoustic emission interpretation / M. Pénicaud, F. Lequien, C. Fisher, A. Recoquilly // *J. of Nondestructive Evaluation*. 2025. Vol. 44, no. 3. Art. 109. P. 1–23. doi: 10.1007/s10921-025-01247-0.
14. Ciaburro G., Iannace G. Machine-learning-based methods for acoustic emission testing // *App. Sci.* 2022. Vol. 12, no. 20. Art. 10476. P. 1–30. doi: 10.3390/app122010476. URL: <https://encyclopedia.pub/entry/32514> (data obrashhenija: 15.09.2025).
15. Wang Ch., Sun Y., Wang X. Image deep learning in fault diagnosis of mechanical equipment // *J. Intell. Manuf.* 2024. Vol. 35. P. 2475–2515. doi: 10.1007/s10845-023-02176-3.
16. A new bearing fault diagnosis method based on modified convolutional neural networks / J. Zhang, Y. Sun, L. Guo, H. Gao, H. Xin, H. Song // *Chinese J. of Aeronautics*. 2020. Vol. 33, no. 2. P. 439–447. doi: 10.1016/j.cja.2019.07.011.
17. Addison P. S. The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance. Boca Raton: CRC Press, 2002. 368 p.
18. Trustworthy clinical AI solutions: A unified review of uncertainty quantification in Deep Learning models for medical image analysis / B. Lambert, F. Forbes, S. Doyle, H. Dehaene, M. Dojat // *Artif Intell Med*. 2024. Vol. 150. P. 102830. doi: 10.1016/j.artmed.2024.102830. URL: <https://pubmed.ncbi.nlm.nih.gov/38553168> (data obrashhenija: 12.09.25).
19. Bearing Fault Diagnosis Based on Improved Convolutional Deep BeliefNetwork / S. Liu, J. Xie, C. Shen, X. Shang, D. Wang, Z. Zhu // *Appl. Sci.* 2020. Vol. 10. P. 6359.
20. An improved random forest algorithm of fault diagnosis for rotating machinery / Z. Wang, M. Zhong, R. Yang, Y. Liu // *Proc. 11<sup>th</sup> CAA Symp. on Fault Detection, Supervision, and Safety for Techn. Proc.: SAFEPROCESS 2019*. Xiamen, China: IEEE, 2019. P. 12–17. doi: 10.1109/SAFEPROCESS45799.2019.9213389.
21. Wang C., Sun Y., Wang X. Image deep learning in fault diagnosis of mechanical equipment // *J. of Intelligent Manufacturing*. 2024. Vol. 35, no. 6. P. 2475–2515. doi: 10.1007/s10845-023-02176-3.
22. Noise-robust fault diagnosis method for rotating machinery based on hybrid-domain graph neural network and SGWT feature enhancement / X. Dong, L. Dong, Z. Liao, S. Liu, Z. Luo // *SSRN*. 2025. 26 p. doi: 10.2139/ssrn.5421600. URL: <https://ssrn.com/abstract=5421600> (data obrashhenija: 15.09.2025).
23. Deep learning methods for heart sounds classification: A systematic review / W. Chen, Q. Sun, X. Chen, G. Xie, H. Wu, C. Xu // *Entropy* 2021. Vol. 23. P. 667. <https://doi.org/10.3390/e23060667> (data obrashheniya: 18.09.2025).
24. Combining visual and acoustic features for audio classification tasks / L. Nanni, Y. M. G. Costa, D. R. Lucio, C. N. Silla, S. Brahmam // *Pattern Recognition Lett.* 2017. Vol. 88. P. 49–56. doi: 10.1016/j.patrec.2017.01.013.
25. Signal processing for the condition-based maintenance of rotating machines via vibration analysis: a tutorial / O. Matania, L. Bachar, E. Bechhoefer, J. Bortman // *Sensors*. 2024. Vol. 24, no. 2. P. 454. doi: 10.3390/s24020454.
26. Ayad A., Bouffard F. Enabling system flexibility in smart grid architecture // *IEEE Trans. on Engin. Management*. 2025. Vol. 72. P. 1892–1908. doi: 10.1109/TEM.2025.3563779.
27. A review of Machine Learning and Deep Learning techniques for anomaly detection in IoT data / R. Alamri, R. K. Murugesan, M. Man, A. F. Abdulateef, M. A. Al-Sharafi, A. A. Alkahtani // *Appl. Sci.* 2021. Vol. 11, no. 12. Art. 5320. P. 1–23. doi: 10.3390/app11125320.
28. Deep learning approaches for robust time of arrival estimation in acoustic emission monitoring / F. Zonzini, D. Bogomolov, T. Dhamija, N. Testoni, L. De Marchi, A. Marzani // *Sensors*. 2022. Vol. 22, no. 3. Art. 1091. doi: 10.3390/s22031091.

29. Mitr D. V. Klassifikacija tipov nazemnoj tehniki po akusticheskomu signalu na osnove algoritma s vremennoj kodirovkoy // Sb. dokl. vseros. nauch.-texn. konf. «Studencheskaja nauchnaja vesna: Mashinostroitelnye tehnologii». M.: OOO «Kvantor-Form», 2023. S. 631–632. URL: studvesna.ru?go=articles&id=3682 (data obrashhenija: 20.11.2025). (In Russ.).

30. Cinar Z. M., Abdusselam R., Gencay E. Audio-based predictive maintenance system architecture // ResearchGate. 2022. URL: [https://www.researchgate.net/figure/Audio-Based-Predictive-Maintenance-System-Architecture-Cinar-et-al-2022\\_fig1\\_389781694](https://www.researchgate.net/figure/Audio-Based-Predictive-Maintenance-System-Architecture-Cinar-et-al-2022_fig1_389781694) (data obrashhenija: 27.06.2025).

31. Verzun N. A., Kolbanev M. O., Salieva A. R. Mnogoagentnyj ansamblevyj algoritm akusticheskogo raspoznvanija narushenij rabotosposobnosti avtonomnogo texnologicheskogo oborudovanija // Informacionno-upravljajushhie sistemy. 2025. № 3. S. 14–24. doi: 10.31799/1684-8853-2025-3-14-24. (In Russ.).

32. Verzun N. A., Kolbanev M. O., Salieva A. R. Razrabotka i issledovanie metoda obuchenija s podkrepleniem dlja akusticheskoy diagnostiki promyshlennogo

oborudovanija // Nauch.-texn. vestn. ITMO. 2025. T. 25, № 5. S. 961–970. doi: 10.17586/2226-1494-2025-25-5-961-970. (In Russ.).

33. Verzun N. A., Kolbanev M. O., Salieva A. R. Adaptivnaja sistema raspoznavanija po akusticheskim priznakam na baze generativno-sostyazatelnyh setej i obuchenija s podkrepleniem // Izv. SPbGETU «LETI». 2026. T. 19, № 1. S. 15–35. (In Russ.).

34. Svid. o gos. reg. programmy dlja EVM № 2025619237. Akusticheskaja sistema diagnostiki neispravnostej promyshlennogo oborudovanija na osnove obuchenija s podkrepleniem (ASD-OP) / A. A. Berdnikova, M. O. Kolbanyov, N. A. Verzun, A. R. Salieva. Pravoobladatel: Nizhegor. GIEU. 2025. Data reg. 10.04.2025; opubl. 14.04.2025. (In Russ.).

35. Svid. o gos. reg. programmy dlja EVM № 2025662662. Mnogoagentnaja ansamblevaja programma akusticheskogo raspoznavanija narushenij rabotosposobnosti avtonomnogo texnologicheskogo oborudovanija (MAAR) / A. R. Salieva, M. O. Kolbanyov, N. A. Verzun. Pravoobladatel: Nizhegor. GIEU. 2025. Data reg. 13.05.2025; opubl. 22.05.2025. (In Russ.).

---

#### Information about the author

**Adelina R. Salieva** – postgraduate student gr. 3933, Department of Information Systems, Saint Petersburg Electrotechnical University.

E-mail: [rustamovna.a3@gmail.com](mailto:rustamovna.a3@gmail.com)

<https://orcid.org/0009-0001-9519-5773>

Статья поступила в редакцию 18.09.2022; принята к публикации после рецензирования 23.12.2025; опубликована онлайн 26.02.2026.

Submitted 18.09.2022; accepted 23.12.2025; published online 26.02.2026.

---