

doi: 10.17586/2226-1494-2025-25-5-961-970

УДК 004.896

Разработка и исследование метода обучения с подкреплением для акустической диагностики промышленного оборудования

Наталья Аркадьевна Верзун^{1✉}, Михаил Олегович Колбанёв², Аделина Рустамовна Салиева³

^{1,2} Санкт-Петербургский государственный экономический университет, Санкт-Петербург, 191023, Российская Федерация

^{1,2} Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» имени В. И. Ульянова (Ленина), Санкт-Петербург, 197376, Российская Федерация

³ Лига цифровой экономики, Москва, 127015, Российская Федерация

¹ Verzun.n@unecon.ru✉, <http://orcid.org/0000-0002-0126-2358>

² mokolbanev@mail.ru, <http://orcid.org/0000-0003-4825-6972>

³ Rustamovna.a3@gmail.com, <https://orcid.org/0009-0001-9519-5773>

Аннотация

Введение. Исследована актуальная задача акустической диагностики автономно работающего промышленного оборудования. Обзор существующих подходов к акустической диагностике, включая методы на основе сверточных нейронных сетей и алгоритмы обучения с учителем, показал их ограничения, такие как необходимость использования для обучения больших объемов размеченных данных, слабая адаптация к изменяющимся условиям и отсутствие механизма принятия решений в реальном времени. Предложен новый подход к акустической диагностике на основе методов обучения с подкреплением, отличающийся способностью к адаптации, высокой устойчивостью к шуму и возможностью непрерывного обучения в динамической среде. **Метод.** Представленный метод определения состояния работоспособности оборудования использует подход, основанный на исследовании акустических сигналов, издаваемых работающим оборудованием. Метод включает построение нейронной сети, выбор аудиозаписей из открытых библиотек аудиофайлов и обучение сети при помощи алгоритма с подкреплением. Процесс акустической диагностики состояния исправности/неисправности промышленного оборудования предполагает четыре этапа: фиксацию в режиме реального времени акустических данных работающего оборудования, извлечение признаков состояния оборудования, обучение с подкреплением нейронной сети и принятие решения о исправности/неисправности оборудования.

Основные результаты. На основе размеченных аудиофайлов из открытых баз данных проведен эксперимент по идентификации различных состояний оборудования: нормальное состояние, начальная стадия дефекта, критическая неисправность. Результаты показали точность классификации от 89,7 % до 98,5 % и среднее время отклика от 0,5 до 0,7 с при низкой вычислительной нагрузке (в среднем загрузка центрального процессора 36,5 % и объем потребляемой оперативной памяти 509 МБ). **Обсуждение.** В отличие от известных систем акустической диагностики, основанных на алгоритмах обучения с учителем нейронных и сверточных нейронных сетей на предварительно размеченных базах данных, содержащих акустические сигналы, издаваемые работающим оборудованием, в предлагаемом подходе реализуется декомпозиция исходных акустических сигналов на спектральные составляющие. Каждая из этих составляющих анализируется и снабжается признаками, отражающими состояние исправности/неисправности оборудования. Такой подход позволяет: использовать алгоритмы обучения с подкреплением для принятия решений на основе стратегии; сократить время обучения модели за счет предварительного выделения значимых признаков; повысить точность диагностики; снизить вычислительную нагрузку и требования к аппаратным ресурсам. Разработанный алгоритм может применяться для непрерывного мониторинга состояния оборудования и предиктивного обслуживания в автономно функционирующих промышленных системах. Его использование позволит надежно и своевременно выявлять, и классифицировать неисправности промышленного оборудования. Алгоритм возможно доработать с учетом требований к интеграции с инфраструктурой интернета вещей, повышения устойчивости к внешним шумам и внедрения более продвинутых алгоритмов обучения с подкреплением, таких как Proximal Policy Optimization или Asynchronous Advantage Actor-Critic.

Ключевые слова

акустическая диагностика, промышленное оборудование, обучение с подкреплением, классификация состояний, RL-агент, спектральный анализ

Ссылка для цитирования: Верзун Н.А., Колбанёв М.О., Салиева А.Р. Разработка и исследование метода обучения с подкреплением для акустической диагностики промышленного оборудования // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 5. С. 961–970. doi: 10.17586/2226-1494-2025-25-5-961-970

Development and research of a reinforcement learning method for acoustic diagnostics of industrial equipment

Natalya A. Verzun¹✉, Mikhail O. Kolbanev², Adelina R. Salieva³

^{1,2} Saint Petersburg State University of Economics, Saint Petersburg, 191023, Russian Federation

^{1,2} Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197376, Russian Federation

³ Digital Economy League, Moscow, 127015, Russian Federation

¹ Verzun.n@unecon.ru✉, <http://orcid.org/0000-0002-0126-2358>

² mokolbanev@mail.ru, <http://orcid.org/0000-0003-4825-6972>

³ Rustamovna.a3@gmail.com, <https://orcid.org/0009-0001-9519-5773>

Abstract

The actual problem of acoustic diagnostics of autonomously operating industrial equipment is investigated. An overview of existing approaches to acoustic diagnostics, including methods based on convolutional neural networks and learning algorithms with a teacher, is provided. Their limitations have been identified, such as the need to use large amounts of labeled data for training, poor adaptation to changing conditions, and the lack of a real-time decision-making mechanism. A new approach to acoustic diagnostics based on reinforcement learning methods is proposed, characterized by adaptability, high resistance to noise and the possibility of continuous learning in a dynamic environment. The proposed method for determining the state of equipment operability uses an approach based on the study of acoustic signals emitted by operating equipment. The method includes building a neural network, selecting audio recordings from open audio file libraries, and training the network using a reinforcement learning algorithm. The process of acoustic diagnostics of the state of serviceability/ malfunction of industrial equipment involves four stages: real-time recording of acoustic data of working equipment, extraction of signs of equipment condition, training with reinforcement of a neural network and making a decision on the serviceability / malfunction of the equipment. Based on tagged WAV audio files from open databases, an experiment was conducted to identify various states of the equipment: normal condition, initial stage of the defect, critical malfunction. The results showed classification accuracy from 89.7 % to 98.5 % and average response time from 0.5 to 0.7 seconds with low computing load (on average 36.5 % CPU and 509 MB RAM). Unlike the well-known acoustic diagnostic systems based on teacher-learning algorithms for neural and convolutional neural networks on pre-marked datasets containing acoustic signals emitted by running equipment, the proposed approach implements the decomposition of the initial acoustic signals into spectral components. Each of these components is analyzed and provided with signs reflecting the state of serviceability or malfunction of the equipment. This approach allows you to: use reinforcement learning algorithms for strategic decision-making; reduce model training time by pre-selecting significant features; improve diagnostic accuracy; reduce computational load and hardware resource requirements. The developed algorithm can be used for continuous monitoring of equipment condition and predictive maintenance in autonomously functioning industrial systems. Its use will allow reliable and timely detection and classification of industrial equipment malfunctions. It is possible to refine the algorithm to meet the requirements for integration with the IoT infrastructure, increase resistance to external noise, and implement more advanced RL algorithms such as PPO.

Keywords

acoustic diagnostics, industrial equipment, reinforcement learning, classification of states, RL agent, spectral analysis

For citation: Verzun N.A., Kolbanev M.O., Salieva A.R. Development and research of a reinforcement learning method for acoustic diagnostics of industrial equipment. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2025, vol. 25, no. 5, pp. 961–970 (in Russian). doi: 10.17586/2226-1494-2025-25-5-961-970

Введение

С появлением большого числа автономно работающих технических систем возникает необходимость в разработке новых мер по обеспечению их надежности и отказоустойчивости [1–4]. Традиционные методы диагностики, такие как периодический осмотр и плановое обслуживание, не всегда способны предотвратить внезапные отказы оборудования [5]. Альтернативой традиционным методам могут выступать интеллектуальные системы непрерывного мониторинга, которые анализируют акустические сигналы, издаваемые обо-

дованием, классифицируют их и оперативно выявляют потенциальные неисправности [6, 7].

Развитие методов машинного обучения: обучение с учителем (Supervised Learning) и сверточные нейронные сети (Convolutional Neural Networks, CNN), значительно повысило эффективность решения задач классификации акустических сигналов [8]. Так, например, в области акустической диагностики использование алгоритма обучения с подкреплением (Reinforcement Learning, RL), основанного на применении глубоких нейронных сетей (Deep Q-Learning) уже продемонстрировало свою эффективность для распознавания

неисправностей в промышленных станках, улучшив точность классификации до 94,5 % [9]. Алгоритм Policy Gradient позволяет адаптироваться к изменяющимся условиям работы оборудования, например, для диагностики подшипников качения [10].

Эти алгоритмы показали хорошие результаты в распознавании звуков, однако их применение на практике сталкивается с рядом ограничений. Такие методы требуют огромных объемов размеченных данных для обучения, что затруднительно в реальных условиях. Они плохо адаптируются к динамически меняющимся условиям функционирования промышленного оборудования и не способны эффективно классифицировать неисправности. Алгоритмы обучались на размеченных «чистых» данных [11], которые представляли звуки работающего оборудования (состояние исправного/неисправного оборудования), а реальные производственные условия зачастую характеризуются высоким уровнем внешних шумов [12]. Альтернативой этим методам может быть обучение с подкреплением, которое представляет собой более гибкий подход. Методы RL адаптируются к изменениям в среде, а также могут эффективно справляться с задачами, требующими последовательных решений в динамических условиях.

Сочетание глубокого обучения с методами RL предоставляет возможность объединить лучшие качества обеих технологий. Гибридные архитектуры, включающие CNN для извлечения признаков и RL-агентов для принятия решений, создают системы, способные эффективно решать задачи классификации и диагностики, даже в условиях изменяющихся характеристик оборудования. Такие подходы уже активно применяются для диагностики дефектов подшипников, мониторинга вибраций турбин и предсказания оставшегося ресурса оборудования [13, 14].

Целью исследования является разработка метода акустической диагностики промышленного оборудования на основе обучения с подкреплением и спектрального анализа сигналов, обеспечивающего высокую точность, адаптивность и устойчивость к шумам при работе в реальном времени. В отличие от известных систем акустической диагностики, с жестко заданной логикой принятия решений, разработанная система

формирует оптимальную стратегию классификации за счет взаимодействия RL-агента с окружающей средой. Метод сочетает извлечение информативных спектральных признаков (амплитудный и частотный спектры, Mel-Frequency Cepstral Coefficients, MFCC) с обучением агента на основе наблюдаемых состояний, что позволяет учитывать стохастическую природу акустических сигналов и реализовать механизм обратной связи для поэтапного обновления диагностической политики в реальном времени [15, 16].

Подход к акустической диагностике промышленного оборудования

Система акустической диагностики, использующая методы RL, в общем случае состоит из: микрофонов и датчиков для сбора акустических данных; модуля предварительной обработки сигналов; модуля классификации звуковых паттернов; модуля принятия решений о техническом состоянии оборудования. Взаимодействие RL-агента и окружающей среды для предлагаемого подхода к акустической диагностике показано на рис. 1.

RL-агент — основной компонент интеллектуального анализа акустических сигналов. При обучении с подкреплением RL-агент обучается взаимодействовать с окружающей средой, выполняя действия на основе текущего состояния и получая за них вознаграждения [17]. В настоящей работе: состояния — спектральные характеристики акустических сигналов, представляющие признаки состояния оборудования; действия — принимаемые решения о классификации состояния оборудования (например, выявление нормальной работы или определение неисправности); награды — система поощрений, которая учитывает такие параметры, как точность диагностики и своевременность обнаружения неисправностей.

RL-агент обучается на основе поступающих данных и обратной связи, анализирует акустические характеристики сигналов, распознает закономерности и принимает решения о состоянии оборудования. На каждом временном шаге RL-агент оценивает текущее состояние системы, определяя, работает ли оборудование в нормальном режиме или имеются признаки неисправно-




Рис. 1. Модель взаимодействия RL-агента и среды в задаче акустической диагностики
Fig. 1. The model of agent-environment interaction in the acoustic diagnostics task

сти. Его эффективность определяется системой наград, которая оценивает, насколько точно и своевременно он выявляет отклонения. Для того чтобы RL-агент мог принимать обоснованные решения, в процессе анализа используются различные признаки состояния.

Признаки состояния представляют собой набор признаков, извлеченных из акустических сигналов, при этом состояние на каждом временном шаге представлено вектором признаков, извлеченных из акустического сигнала. Такими признаками являются: амплитудный спектр (позволяет анализировать интенсивность сигналов в различных диапазонах частот); частотный спектр (отображает распределение частот в сигнале, выявляя потенциальные аномалии); MFCC.

Выделение и учет этих признаков позволяет проводить более детальный анализ сигналов, что особенно важно при диагностике сложных акустических процессов и благодаря чему достигается: устойчивость к шуму, возможность фильтрации случайных помех и выделение ключевых акустических характеристик работающего оборудования.

Математическая модель

Признаки акустических сигналов образуют многомерный вектор данных, который помогает RL-агенту распознавать изменения в звуках и повышать точность диагностики. На временном шаге t состояние s_t представляет собой многомерный вектор, включающий признаки [18–21] перечисленные в разделе «Подход к акустической диагностике промышленного оборудования».

Амплитудный спектр извлекается модулем предварительной обработки сигналов с использованием быстрого преобразования Фурье:

$$X(f) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi fn/N}, \quad (1)$$

где $x(n)$ — временной сигнал; N — количество отсчетов; f — частота; j — мнимая единица.

Частотный спектр определяется как набор значений f_i , соответствующих дискретным частотам:

$$f_i = \frac{if_s}{N_{FFT}}, i = 0, 1, \dots, N_{FFT}, \quad (2)$$

где f_s — частота дискретизации; N_{FFT} — размер быстрого преобразования Фурье.

MFCC имеют вид

$$MFCC(k) = \sum_{m=1}^M \log(|F_m|) \cos \left[k(m-0,5) \frac{\pi}{M} \right], \quad (3)$$

где M — количество фильтров в мел-шкале; F_m — спектральная энергия в фильтре m ; k — индекс коэффициента MFCC.

Состояние s_t представляется как вектор

$$s_t = \{f_1, f_2, \dots, f_i\}, t = 1, 2, \dots, \quad (4)$$

где f_i — спектральные признаки, извлеченные из акустического сигнала на момент времени t .

Действия $a \in A$ представляют собой выбор одного из возможных состояний оборудования. Например: a_1 — оборудование в нормальном состоянии, a_2 — обнаружен незначительный дефект, a_3 — критическая неисправность. Для дискретного пространства действий используется политика $\pi(a|s; \theta)$, которая определяет вероятность выбора действия a при наблюдаемом состоянии s

$$\pi(a|s; \theta) = P(A = a|S = s; \theta), \quad (5)$$

где θ — параметры модели (нейронной сети); $\pi(a|s; \theta)$ — вероятность выбора действия a в состоянии s ; s — текущее состояние (вектор признаков); a — конкретное действие.

Награда τ вычисляется как комбинация точности классификации и своевременности:

$$\tau_e = \omega_1 Accuracy(a_t, \hat{a}) - \omega_2 Delay(a_t), \quad (6)$$

где $Accuracy(a_t, \hat{a})$ — бинарный показатель точности классификации (1 — правильная классификация, 0 — ошибочная); $Delay(a_t)$ — временной штраф за позднее обнаружение дефекта; ω_1 и ω_2 — веса, задающие баланс между точностью и своевременностью.

Обучение RL-агента направлено на максимизацию ожидаемой совокупной награды:

$$J(\theta) = E_{\pi_\theta} \left[\sum_{t=0}^T \gamma^t \tau_t \right], \quad (7)$$

где γ — коэффициент дисконтирования, задающий приоритет краткосрочным наградам; θ — параметры нейронной сети, представляющей политику. Обновление параметров будет производиться с помощью градиентного метода.

После извлечения признаков из акустического сигнала RL-агент выполняет классификацию состояния оборудования, определяя возможные неисправности. Однако для эффективного функционирования системы недостаточно просто классифицировать сигналы — необходимо также учитывать неопределенность, адаптироваться к изменениям в данных и минимизировать ошибки диагностики. Эти задачи решает модуль принятия решений, который включает компоненты: политику выбора действий — $\pi(a|s)$; функцию ценности — $V(s; \theta)$; систему оценки уверенности — $Confidence(a|s)$; механизм обучения с использованием критерия ошибки, т. е. функцию потерь — L ; градиентное обновление параметров нейронной сети — θ .

Политика выбора действий $\pi(a|s)$ определяет, какое решение RL-агент примет на основе наблюдаемого состояния оборудования. Задается вероятностной моделью:

$$\pi(s, \theta) = \frac{\exp(Q(s, a))}{\sum_{a' \in A} \exp(Q(s, a'))}, \quad (8)$$

где $\pi(s, \theta)$ — оценка качества действия a в состоянии s (функция ценности); $Q(s, a)$ — оценка качества действия a в состоянии s ; a' — произвольное действие из множества всех возможных действий A в состоянии

s ; a — параметр, который регулирует баланс между исследованием и эксплуатацией.

RL-агент выбирает действие на основе вероятности $\pi(a|s)$:

$$a_t = \arg \max \pi(a|s_t), \quad (9)$$

где a_t — выбранное действие в момент t ; $\arg \max$ — операция, возвращающая аргумент (в данном случае действие), при котором функция достигает максимума; $\pi(a|s_t)$ — вероятность выбора действия a в состоянии s_t . Для оценки $Q(s, a)$ используется алгоритм Deep Q-Learning.

Система оценки уверенности позволяет учитывать степень надежности каждого принятого решения:

$$\text{Confidence}(a|s) = \pi(a|s), \quad (10)$$

если уверенность ниже порогового значения δ , то решение откладывается, а сигнал передается для повторного анализа.

Механизм обратной связи корректирует модель RL-агента на основе предыдущего опыта, повышая ее точность и может быть организован через механизм обучения с использованием критерия ошибок (функции потерь):

$$L = \frac{1}{B} \sum_{i=1}^B [Q(s_i, a_i) - \hat{r}_i]^2, \quad (11)$$

где B — размер обучающей выборки; $Q(s_i, a_i)$ — предсказанное Q -значение для пары (состояние, действие); r_i — фактическое значение награды; $\sum_{i=1}^B [Q(s_i, a_i) - \hat{r}_i]^2$ — квадрат ошибки.

Градиентное обновление:

$$\theta \leftarrow \theta - \eta \times \nabla_{\theta} L, \quad (12)$$

где θ — параметры модели; η — скорость обучения; $\nabla_{\theta} L$ — градиент функции потерь по параметрам.

Алгоритм обучения

Используя представленную математическую модель, была создана программа [22], реализующая метод акустической диагностики (рис. 2). В ее основе лежат алгоритмы обработки сигналов, механизм обучения RL-агента и модуль принятия решений, что обеспечивает автоматическое выявление неисправностей и адаптацию к изменяющимся условиям эксплуатации оборудования. Реализация включает в себя обработку акустических сигналов и динамическое обновление модели посредством обратной связи, что повышает надежность и эффективность диагностики.

Приведенные в разделе «Математическая модель» соотношения лежат в основе процесса функционирования системы акустической диагностики, которая реализована поэтапно в соответствии с блок-схемой на рис. 2.

Приведем сопоставление математических выражений с этапами реализации предложенного алгоритма.

Этап 1. Инициализация системы. Выполняется начальная настройка системы, которая включает установку параметров обучения RL-агента, инициализацию структуры модели, логгера и директории хранения. На этапе 1 происходит задание параметров и скорости



Рис. 2. Этапы акустической диагностики

Fig. 2. Stages of acoustic diagnostics

обучения, которые далее участвуют в формуле градиентного обновления (12).

Этап 2. Загрузка данных. Акустический сигнал подвергается сегментации и нормализации, подготавливается для последующего анализа.

Этап 3. Аугментация. Применяются преобразования, имитирующие вариации внешних условий. Отметим, что на этапе 3 не используется отдельная формула, но он влияет на корректность построения вектора признаков (4).

Этап 4. Извлечение признаков. Извлечение реализуется с помощью быстрого преобразования Фурье формула (1), вычисления частотных составляющих (2) и извлечения MFCC (3).

Этап 5. Обучение модели. На основе извлеченных признаков формируется вектор состояния агента (4). Процесс обучения включает оптимизацию параметров модели θ , обновляемых по методу градиентного спуска на основе функций потерь (11) и (12).

Этап 6. Буфер воспроизведения. Осуществляется выборка обучающих примеров с приоритетами, что позволяет реализовать эффективное обучение по методу Deep Q-Learning (8)–(10).

Этап 7. Обновление модели. Производится вычисление целевой функции награды (6), а также обновление целевой сети Q-функции, что соответствует максимизации ожидаемой совокупной награды (7).

Этап 8. Оценка. Анализируются Accuracy, Loss и Reward — метрики, основанные на функции потерь, точности классификации и награде (формулы см., например, в [12]).

Этап 9. Интеграция. На данном этапе система отправляет уведомления при критических состояниях, определенных на основе вероятностной политики (5).

Этап 10. Сохранение. Выполняется сохранение обученной модели с параметрами θ для последующего применения и дообучения.

Описание эксперимента

Целью эксперимента являлась оценка эффективности разработанного алгоритма RL при диагностике различных состояний промышленного оборудования на основе анализа акустических сигналов. В рамках исследования основное внимание уделялось способности модели точно и своевременно классифицировать техническое состояние оборудования, а также устойчивости алгоритма к фоновым шумам и изменяющимся условиям эксплуатации.

Исходные данные. Для обеспечения воспроизводимости эксперимента и репрезентативности обучающей выборки были использованы открытые общедоступные базы данных, содержащие акустические и вибрационные сигналы промышленного оборудования в различных состояниях:

- Case Western Reserve University Bearing Data Center — база данных, включающая записи вибрационных и акустических сигналов подшипников с контролируемыми дефектами различной степени [23];
- MIMII Dataset (Malfunctioning Industrial Machine Investigation and Inspection) — содержит акустиче-

ские записи насосов, вентиляторов, клапанов и компрессоров в нормальном и аномальном состояниях [24];

- DCASE Challenge 2020 Dataset — акустические данные для задач мониторинга технического состояния машин в условиях фоновых шумов и неопределенности среды [25].

Для обучения и тестирования модели применялись аудиофайлы в формате Waveform Audio File Format, снабженные метками состояний оборудования. Предварительная обработка включала нормализацию сигналов, выделение спектральных признаков (амплитудный и частотный спектр, MFCC) и формирование входных векторов признаков.

Оценка алгоритма акустического распознавания.

Тестирование алгоритма проводилось на различных типах оборудования для оценки его эффективности в распознавании аномалий. Для оценки качества классификации были использованы общепринятые метрики (Accuracy, Precision, Recall, F1-мера). Важность их применения в данной работе обусловлена не только общепринятостью, но и необходимостью комплексной количественной оценки работы RL-агента [23]: Accuracy, Precision и Recall позволяют понять компромисс между количеством ложных срабатываний и пропущенных дефектов, что критически важно в задачах промышленной диагностики; F1-мера отражает обобщенную эффективность диагностики при наличии несбалансированных классов.

Также в рамках оценки рассчитывался показатель ложных срабатываний, что особенно важно в контексте промышленной эксплуатации, где ложные тревоги ведут к экономическим потерям.

Целевые классы и постановка задачи.

Эксперимент охватывает три целевых состояния оборудования: нормальное состояние — сигнал характеризуется стабильной спектральной структурой без аномалий; начальная стадия дефекта — слабовыраженные отклонения в сигнале, указывающие на поверхностные повреждения (трещины, износ); критическая неисправность — ярко выраженные частотные всплески и высокоамплитудные аномалии, отражающие значительные дефекты (глубокие трещины, разрушение элемента).

RL-агент обучался классифицировать текущие состояния на основе анализа извлеченных признаков, а также адаптироваться к изменениям акустической картины за счет механизма обратной связи и функции награды, описанной в математической модели.

Все метрики рассчитывались на тестовой выборке, сформированной по принципу стратифицированного разбиения (80/20), с последующим усреднением по результатам 5 независимых запусков модели.

Результаты. Для оценки эффективности разработанного алгоритма обучения было проведено тестирование. Основное внимание уделялось точности классификации различных состояний подшипника, а также способности алгоритма идентифицировать неисправности в различных типах промышленного оборудования.

Результаты тестирования алгоритма обучения представлены в табл. 1 и 2. Сравнение метрик по типам оборудования и неисправностей приведено на рис. 3.

Таблица 1. Точность классификации по состояниям подшипника

Table 1. Accuracy of classification according to bearing conditions

Состояние подшипника	Точность классификации, %	Время отклика, с	Описание
Нормальное состояние	98,5	0,5	Сигналы подшипника без признаков повреждений
Начальная стадия дефекта	94,2	0,6	Легкие повреждения, такие как трещины или износ
Критическая неисправность	89,7	0,7	Серьезные повреждения: глубокие трещины и сильный износ




Рис. 3. Сравнение метрик по типам оборудования и неисправностей

Fig. 3. Comparison of metrics by type of equipment and malfunction

Таблица 2. Сравнение загрузки CPU, RAM и времени выполнения по типу оборудования

Table 2. Comparison of CPU, RAM, and execution time by hardware type

Тип оборудования	Тип нарушения	Загрузка CPU, %	Загрузка RAM, МБ	Время отклика, с
Насос	Вибрация	35	512	0,21
Вентиляторы	Неравномерный шум	38	490	0,26
Компрессоры	Низкочастотные колебания	40	530	0,27
Клапаны	Аномальные вибрации	33	505	0,25

Для оценки применимости разработанного алгоритма в условиях реального времени особое внимание уделялось его вычислительной эффективности. В рамках экспериментов измерялись ключевые показатели нагрузки на систему: средняя загрузка центрального процессора (CPU), объем потребляемой оперативной памяти (RAM) и время отклика алгоритма. В табл. 2 показаны показатели нагрузки на компьютер и время отклика алгоритма.

Обсуждение

Проведенные исследования подтвердили эффективность предложенного RL-алгоритма в задачах акустической диагностики неисправностей промышленного оборудования. Средние значения Accuracy, Recall и F1-меры варьируются в пределах 90–95 %, что свидетельствует о надежности и устойчивости алгоритма при обработке сложных акустических сигналов.

Наибольшие показатели достигнуты при анализе вибраций насосов и клапанов, где F1-мера составила 92,5 % и 93,5 %. Это указывает на способность модели точно классифицировать как нормальные, так и аномальные состояния. В случае вентиляторов и компрессоров, несмотря на более сложные акустические профили, алгоритм продемонстрировал стабильные результаты с F1-мерой 90 % и 89 % соответственно.

С точки зрения вычислительной эффективности, алгоритм показал низкую нагрузку на систему: средняя загрузка CPU составила 36,5 %, потребление RAM — около 509 МБ, а среднее время отклика — 0,25 с. Это делает его пригодным для использования в системах реального времени.

Низкая загрузка CPU и оперативной памяти позволяет интегрировать предложенный метод в промышленные контроллеры и edge-устройства, обеспечивая непрерывную диагностику без существенной нагрузки на вычислительные ресурсы.

Однако, несмотря на положительные результаты, метод имеет ряд ограничений:

- необходима калибровка параметров награды и архитектуры RL-агента под конкретный тип оборудования;
- использование алгоритма требует предварительного извлечения спектральных признаков, что повышает сложность подготовки данных;
- в текущей реализации не учитываются мультисенсорные источники (вибрация, температура), которые могли бы улучшить устойчивость диагностики.

Заключение

Проведен анализ существующих подходов к акустической диагностике промышленного оборудования, включая методы машинного обучения с учителем и сверточные нейронные сети. Применение данных подходов на практике позволяет достигать высокой точности распознавания неисправностей (до 94,5 %) и успешно выявлять различные аномалии в звуках работающего оборудования. Однако они обладают рядом ограничений: требуют большого количества размеченных данных, плохо адаптируются к изменяющимся условиям эксплуатации и не обеспечивают автономного принятия решений в реальном времени.

Предложен новый подход, основанный на методах обучения с подкреплением, отличающийся высокой адаптивностью, наличием механизма обратной связи и способностью работать в условиях стохастической и динамически изменяющейся среды. Разработана блок-схема алгоритма, включающая извлечение спек-

тральных признаков, обучение агента и принятие решений на основе оптимальной стратегии.

Проведен эксперимент на размеченных аудиофайлах из открытой базы данных Case Western Reserve University. В ходе экспериментов модель успешно идентифицировала состояния оборудования даже при наличии фоновых промышленных шумов, что подтверждает ее пригодность для работы в реальных производственных условиях.

Благодаря низкой вычислительной нагрузке: в среднем загрузка центрального процессора составляла 36,5 % и объем потребляемой оперативной памяти 509 МБ, а также быстрому времени отклика 0,5–0,7 с, предложенный алгоритм может быть эффективно реализован на edge-устройствах и промышленных контроллерах. Это открывает возможности его интеграции в системы предиктивного обслуживания и мониторинга оборудования в реальном времени, обеспечивая своевременное выявление неисправностей, снижение внеплановых простоев и повышение общей надежности технологических процессов.

Практическая значимость работы заключается в повышении точности и скорости диагностики, что способствует снижению рисков дорогостоящих отказов и оптимизации процессов технического обслуживания. В перспективе предложенный подход может быть усовершенствован за счет интеграции с технологиями интернета вещей, повышения устойчивости к шуму, внедрения более сложных алгоритмов обучения с подкреплением, таких как Proximal Policy Optimization или Asynchronous Advantage Actor-Critic, а также испытания на реальных промышленных объектах.

Литература

1. Винограденко А.М., Будко Н.П. Адаптивный контроль технического состояния автономных сложных технических объектов на основе интеллектуальных технологий // T-Comm: Телекоммуникации и Транспорт. 2020. Т. 14. № 1. С. 25–35. <https://doi.org/10.36724/2072-8735-2020-14-1-25-35>
2. Богатырев В.А., Богатырев С.В., Богатырев А.В. Оценка готовности компьютерной системы к своевременному обслуживанию запросов при его совмещении с информационным восстановлением памяти после отказов // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 3. С. 608–617. <https://doi.org/10.17586/2226-1494-2023-23-3-608-617>
3. Bogatyrev V., Vinokurova M. Control and safety of operation of duplicated computer systems // Communications in Computer and Information Science. 2017. V. 700. P. 331–342. https://doi.org/10.1007/978-3-319-66836-9_28
4. Bogatyrev V.A. Exchange of duplicated computing complexes in fault-tolerant systems // Automatic Control and Computer Sciences. 2011. V. 45. N 5. P. 268–276. <https://doi.org/10.3103/s014641161105004x>
5. Мартюгов А.С., Ершов Е.В., Виноградова Л.Н., Варфоломеев И.А. Диагностика промышленного оборудования методом акустического контроля // Оптико-электронные приборы и устройства в системах распознавания образов и обработки изображений: Материалы XVI Международной научно-технической конференции. Курск: Юго-Западный государственный университет, 2021. С. 172–174.
6. Верзун Н.А., Колбанёв М.О., Салиева А.Р. Многоагентный ансамблевый алгоритм акустического распознавания нарушений работоспособности автономного технологического оборудования // Информационно-управляющие системы. 2025. № 3 (136). С. 14–24. <https://doi.org/10.31799/1684-8853-2025-3-14-24>

References

1. Vinogradenko A.M., Budko N.P. Adaptive control of technical condition of autonomous complex technical objects on the basis of intelligent technologies. Electrostatic gyroscope in spacecraft attitude reference systems. *T-Comm*, 2020, vol. 14, no. 1, pp. 25–35. (in Russian). <https://doi.org/10.36724/2072-8735-2020-14-1-25-35>
2. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Assessment of the readiness of a computer system for timely servicing of requests when combined with information recovery of memory after failures. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2023, vol. 23, no. 3, pp. 608–617. (in Russian). <https://doi.org/10.17586/2226-1494-2023-23-3-608-617>
3. Bogatyrev V., Vinokurova M. Control and safety of operation of duplicated computer systems. *Communications in Computer and Information Science*, 2017, vol. 700, pp. 331–342. https://doi.org/10.1007/978-3-319-66836-9_28
4. Bogatyrev V.A. Exchange of duplicated computing complexes in fault-tolerant systems. *Automatic Control and Computer Sciences*, 2011, vol. 45, no. 5, pp. 268–276. <https://doi.org/10.3103/s014641161105004x>
5. Martiugov A.S., Ershov E.V., Vinogradova L.N., Varfolomeev I.A. Diagnostics of industrial equipment using acoustic testing. *Proc. of the Optical-Electronic Devices and Instruments in Image Recognition and Processing Systems*, 2021, pp. 172–174. (in Russian)
6. Verzun N.A., Kolbanov M.O., Salieva A.R. Multi-agent ensemble algorithm for acoustic recognition of malfunctions of autonomous technological equipment. *Information and Control Systems*, 2025, no. 3, pp. 14–24. (in Russian). <https://doi.org/10.31799/1684-8853-2025-3-14-24>
7. Shchegolkov M.V., Zinkin S.A. Overview of the main model-free reinforcement learning approaches. *Proc. of the Energy and Automation in Modern Society*, 2024, pp. 91–95. (in Russian)

7. Щегольков М.В., Зинкин С.А. Обзор основных подходов обучения с подкреплением на основе обучения без знания модели // Энергетика и автоматизация в современном обществе: Материалы VII Всероссийской научно-практической конференции обучающихся и преподавателей. СПб: Санкт-Петербургский государственный университет промышленных технологий и дизайна, 2024. С. 91–95.
8. Ye L., Ma X., Wen C. Rotating machinery fault diagnosis method by combining time-frequency domain features and CNN knowledge transfer // *Sensors*. 2021. V. 21. N 24. P. 8168. <https://doi.org/10.3390/s21248168>
9. Shao S., McAleer S., Yan R., Baldi P. Highly accurate machine fault diagnosis using deep transfer learning // *IEEE Transactions on Industrial Informatics*. 2019. V. 15. N 4. P. 2446–2455. <https://doi.org/10.1109/tii.2018.2864759>
10. Souza R.M., Nascimento E.G.S., Miranda U.A., Silva W.J.D., Lepikson H.A.. Deep learning for diagnosis and classification of faults in industrial rotating machinery // *Computers and Industrial Engineering*. 2021. V. 153. P. 107060. <https://doi.org/10.1016/j.cie.2020.107060>
11. Lyu P., Zhang K., Yu W., Wang B., Liu C. A novel RSG-based intelligent bearing fault diagnosis method for motors in high-noise industrial environment // *Advanced Engineering Informatics*. 2022. V. 52. P. 101564. <https://doi.org/10.1016/j.aei.2022.101564>
12. Zhang J., Koppel A., Bedi A.S., Szepesvari C., Wang M., Variational policy gradient method for reinforcement learning with general utilities // *arXiv*. 2020. arXiv:2007.02151. <https://doi.org/10.48550/arXiv.2007.02151>
13. Chen D., Peng P., Huang T., Tian Y. Deep reinforcement learning with spiking Q-learning // *arXiv*. 2022. arXiv:2201.09754. <https://doi.org/10.48550/arXiv.2201.09754>
14. Верзун Н.А., Колбанёв М.О., Салиева А.Р. Анализ перспектив обучения умных автономных логистических систем на основе оптимизации функции ценности // *Известия СПбГЭТУ ЛЭТИ*. 2024. Т. 17. № 10. С. 28–39. <https://doi.org/10.32603/2071-8985-2024-17-10-28-39>
15. Tama B.A., Vania M., Lee S., Lim S. Recent advances in the application of deep learning for fault diagnosis of rotating machinery using vibration signals // *Artificial Intelligence Review*. 2023. V. 56. N 5. P. 4667–4709. <https://doi.org/10.1007/s10462-022-10293-3>
16. Wang R., Zhan X., Bai H., Dong E., Cheng Z., Jia X. A review of fault diagnosis methods for rotating machinery using infrared thermography // *Micromachines*. 2022. V. 13. N 10. P. 1644. <https://doi.org/10.3390/mi13101644>
17. Ramaswamy A., Hüllermeier E. Deep Q-Learning: theoretical insights from an asymptotic analysis // *arXiv*. 2020. arXiv:2008.10870. <https://doi.org/10.48550/arXiv.2008.10870>
18. Hansen N., Su H., Wang X. Stabilizing Deep Q-Learning with ConvNets and vision transformers under data augmentation // *Proc. of the 35th International Conference on Neural Information Processing Systems*. 2021. P. 3680–3693.
19. Haq A.S., Nasrun M., Setianingsih C., Murti M.A. Speech recognition implementation using MFCC and DTW algorithm for home automation // *Proc. of the International Conference on Electrical Engineering Computer Science and Informatics*. 2020. V. 7. P. 78–85. <https://doi.org/10.11591/eeesi.v7.2041>
20. Sutton R.S., Barto A.G. *Reinforcement Learning: An Introduction*. Bradford Books, 2018. 552 p.
21. Das O., Das D.B., Birant D. Machine learning for fault analysis in rotating machinery: A comprehensive review // *Heliyon*. 2023. V. 9. N 6. P. e17584. <https://doi.org/10.1016/j.heliyon.2023.e17584>
22. Свидетельство о государственной регистрации программы для ЭВМ № 2025619237. Акустическая система диагностики неисправностей промышленного оборудования на основе обучения с подкреплением (АСД-ОП). Номер и дата поступления заявки: 2025617991 10.04.2025. Опубликовано 14.04.2025 Бюл. № 4 / Бердникова А.А., Колбанёв М.О., Верзун Н.А., Салиева А.Р. Правообладатель: Государственное бюджетное образовательное учреждение высшего образования «Нижегородский государственный инженерно-экономический университет».
23. Moharam M.H., Hany O., Hany A., Mahmoud A., Mohamed M., Saeed S. Anomaly detection using machine learning and adopted digital twin concepts in radio environments // *Scientific Reports*. 2025. V. 15. P. 18352. <https://doi.org/10.1038/s41598-025-02759-5>
24. Purohit H.P., Tanabe R., Ichige K., Endo T., Nikaido Y., Suefusa K., Kawaguchi Y. MIMII Dataset: sound dataset for malfunctioning
8. 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, pp. 8168. <https://doi.org/10.3390/s21248168>
9. Shao S., McAleer S., Yan R., Baldi P. Highly accurate machine fault diagnosis using deep transfer learning. *IEEE Transactions on Industrial Informatics*, 2019, vol. 15, no. 4, pp. 2446–2455. <https://doi.org/10.1109/tii.2018.2864759>
10. Souza R.M., Nascimento E.G.S., Miranda U.A., Silva W.J.D., Lepikson H.A.. Deep learning for diagnosis and classification of faults in industrial rotating machinery. *Computers and Industrial Engineering*, 2021, vol. 153, pp. 107060. <https://doi.org/10.1016/j.cie.2020.107060>
11. Lyu P., Zhang K., Yu W., Wang B., Liu C. A novel RSG-based intelligent bearing fault diagnosis method for motors in high-noise industrial environment. *Advanced Engineering Informatics*, 2022, vol. 52, pp. 101564. <https://doi.org/10.1016/j.aei.2022.101564>
12. Zhang J., Koppel A., Bedi A.S., Szepesvari C., Wang M., Variational policy gradient method for reinforcement learning with general utilities. *arXiv*, 2020, arXiv:2007.02151. <https://doi.org/10.48550/arXiv.2007.02151>
13. Chen D., Peng P., Huang T., Tian Y. Deep reinforcement learning with spiking Q-learning. *arXiv*, 2022, arXiv:2201.09754. <https://doi.org/10.48550/arXiv.2201.09754>
14. Verzun N.A., Kolbanev M.O., Salieva A.R. Analysis learning prospects of smart autonomous logistics systems based on value function optimization. *LETI Transactions on Electrical Engineering & Computer Science*, 2024, vol. 17, no. 10, pp. 28–39. (in Russian). <https://doi.org/10.32603/2071-8985-2024-17-10-28-39>
15. Tama B.A., Vania M., Lee S., Lim S. Recent advances in the application of deep learning for fault diagnosis of rotating machinery using vibration signals. *Artificial Intelligence Review*, 2023, vol. 56, no. 5, pp. 4667–4709. <https://doi.org/10.1007/s10462-022-10293-3>
16. Wang R., Zhan X., Bai H., Dong E., Cheng Z., Jia X. A review of fault diagnosis methods for rotating machinery using infrared thermography. *Micromachines*, 2022, vol. 13, no. 10, pp. 1644. <https://doi.org/10.3390/mi13101644>
17. Ramaswamy A., Hüllermeier E. Deep Q-Learning: theoretical insights from an asymptotic analysis. *arXiv*, 2020, arXiv:2008.10870. <https://doi.org/10.48550/arXiv.2008.10870>
18. Hansen N., Su H., Wang X. Stabilizing Deep Q-Learning with ConvNets and vision transformers under data augmentation. *Proc. of the 35th International Conference on Neural Information Processing Systems*, 2021, pp. 3680–3693.
19. Haq A.S., Nasrun M., Setianingsih C., Murti M.A. Speech recognition implementation using MFCC and DTW algorithm for home automation. *Proc. of the International Conference on Electrical Engineering Computer Science and Informatics*, 2020, vol. 7, pp. 78–85. <https://doi.org/10.11591/eeesi.v7.2041>
20. Sutton R.S., Barto A.G. *Reinforcement Learning: An Introduction*. Bradford Books, 2018. 552 p.
21. Das O., Das D.B., Birant D. Machine learning for fault analysis in rotating machinery: A comprehensive review. *Heliyon*, 2023, vol. 9, no. 6, pp. e17584. <https://doi.org/10.1016/j.heliyon.2023.e17584>
22. Berdnikova A.A., Kolbanev M.O., Verzun N.A., Salieva A.R. *Acoustic system for diagnostics of industrial equipment faults based on reinforcement learning (ASD-OP)*. Certificate of state registration of the computer program RU 2025619237. 2025. (in Russian)
23. Moharam M.H., Hany O., Hany A., Mahmoud A., Mohamed M., Saeed S. Anomaly detection using machine learning and adopted digital twin concepts in radio environments. *Scientific Reports*, 2025, vol. 15, pp. 18352. <https://doi.org/10.1038/s41598-025-02759-5>
24. Purohit H.P., Tanabe R., Ichige K., Endo T., Nikaido Y., Suefusa K., Kawaguchi Y. MIMII Dataset: sound dataset for malfunctioning industrial machine investigation and inspection. *Proc. of the Detection and Classification of Acoustic Scenes and Events 2019 Workshop (DCASE2019)*, 2019, pp. 209–213. <https://doi.org/10.33682/m76f-d618>
25. Koizumi Y., Kawaguchi Y., Imoto K., Nakamura T., Nikaido Y., Tanabe R., Purohit H., Suefusa K., Endo T., Yasuda M., Harada N. Description and discussion on DCASE2020 challenge Task2: unsupervised anomalous sound detection for machine condition monitoring. *arXiv*, 2020, arXiv:2006.05822. <https://doi.org/10.48550/arXiv.2006.05822>

- industrial machine investigation and inspection // Proc. of the Detection and Classification of Acoustic Scenes and Events 2019 Workshop (DCASE2019). 2019. P. 209–213. <https://doi.org/10.33682/m76f-d618>
25. Koizumi Y., Kawaguchi Y., Imoto K., Nakamura T., Nikaido Y., Tanabe R., Purohit H., Suefusa K., Endo T., Yasuda M., Harada N. Description and discussion on DCASE2020 challenge Task2: unsupervised anomalous sound detection for machine condition monitoring // arXiv. 2020. arXiv:2006.05822. <https://doi.org/10.48550/arXiv.2006.05822>

Авторы

Верзун Наталья Аркадьевна — кандидат технических наук, доцент, доцент, Санкт-Петербургский государственный экономический университет, Санкт-Петербург, 191023, Российская Федерация; доцент, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» имени В. И. Ульянова (Ленина), Санкт-Петербург, 197376, Российская Федерация, [sc 57208320400](https://orcid.org/0000-0002-0126-2358), <http://orcid.org/0000-0002-0126-2358>, Verzun.n@unecon.ru

Колбанёв Михаил Олегович — доктор технических наук, профессор, профессор, Санкт-Петербургский государственный экономический университет, Санкт-Петербург, 191023, Российская Федерация; профессор, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» имени В. И. Ульянова (Ленина), Санкт-Петербург, 197376, Российская Федерация, [sc 6506189057](https://orcid.org/0000-0003-4825-6972), <http://orcid.org/0000-0003-4825-6972>, mokolbanev@mail.ru

Салиева Аделина Рустамовна — аспирант, младший аналитик, Лига цифровой экономики, Москва, 127015, Российская Федерация, <https://orcid.org/0009-0001-9519-5773>, Rustamovna.a3@gmail.com

Статья поступила в редакцию 28.06.2025

Одобрена после рецензирования 08.08.2025

Принята к печати 24.09.2025

Authors

Natalya A. Verzun — PhD, Associate Professor, Associate Professor, Saint Petersburg State University of Economics, Saint Petersburg, 191023, Russian Federation; Associate Professor, Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197376, Russian Federation, [sc 57208320400](https://orcid.org/0000-0002-0126-2358), <http://orcid.org/0000-0002-0126-2358>, Verzun.n@unecon.ru

Mikhail O. Kolbanev — D.Sc., Full Professor, Saint Petersburg State University of Economics, Saint Petersburg, 191023, Russian Federation; Professor, Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197376, Russian Federation, [sc 6506189057](https://orcid.org/0000-0003-4825-6972), <http://orcid.org/0000-0003-4825-6972>, mokolbanev@mail.ru

Adelina R. Salieva — PhD Student, Junior Analyst, Digital Economy League, Moscow, 127015, Russian Federation, <https://orcid.org/0009-0001-9519-5773>, Rustamovna.a3@gmail.com

Received 28.06.2025

Approved after reviewing 08.08.2025

Accepted 24.09.2025



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»