



Многоагентный ансамблевый алгоритм акустического распознавания нарушений работоспособности автономного технологического оборудования

Н. А. Верзун^{а,б}, канд. техн. наук, доцент, orcid.org/0000-0002-0126-2358, verzun.n@unecon.ru

М. О. Колбанев^{а,б}, доктор техн. наук, профессор, orcid.org/0000-0003-4825-6972

А. Р. Салиева^а, аспирант, orcid.org/0009-0001-9519-5773

^аСанкт-Петербургский государственный электротехнический университет «ЛЭТИ», Профессора Попова ул., 5, Санкт-Петербург, 197376, РФ

^бСанкт-Петербургский государственный экономический университет, наб. канала Грибоедова, 30-32, Санкт-Петербург, 191023, РФ

Введение: в условиях высокоавтоматизированных производств традиционные методы диагностики функционирования технологического оборудования, основанные на визуальном осмотре или механических датчиках, часто оказываются недостаточными. С учетом автономных режимов работы оборудования, использующего искусственный интеллект, все большее значение приобретают автоматические системы мониторинга с привлечением акустических данных, которые могут сигнализировать о неисправностях без вмешательства в процесс работы. **Цель:** разработать многоагентный ансамблевый алгоритм акустического распознавания, способный выявлять различные типы нарушений в работе автономных технических систем с точностью не менее 90 %, F1-мерой $\geq 0,85$. **Результаты:** предложен новый подход к акустическому распознаванию неисправностей автономного технологического оборудования, основанный на многоагентном ансамблевом алгоритме. Разработана архитектура многоагентной системы, включающая четырех специализированных агентов, анализирующих различные параметры акустических сигналов: 1) агент спектрального анализа оценивает изменения частотного состава акустического сигнала, выявляя аномальные колебания, характерные для механических повреждений и неисправностей; 2) агент временного анализа отслеживает временные паттерны акустических данных, анализируя изменения амплитуды и продолжительности сигналов, что позволяет выявлять кратковременные сбои и нерегулярные шумы; 3) агент анализа функционирования оборудования соотносит акустические данные с рабочими режимами оборудования, выявляя отклонения от нормального функционирования; 4) агент анализа внешнего окружения учитывает внешние шумовые факторы и фильтрует их, повышая точность диагностики путем исключения посторонних звуков. Агенты реализованы и обучены с использованием методов машинного и глубокого обучения. В рамках исследования проведен эксперимент, в котором оценена эффективность предложенного алгоритма. Точность распознавания неисправностей достигала не менее 90 %. Проведенное исследование показало, что применение многоагентного подхода позволяет повысить надежность диагностики за счет объединения результатов работы различных аналитических моделей. **Практическая значимость:** программный код, реализующий ансамблевый алгоритм распознавания, может применяться для диагностики широкого круга автономных систем.

Ключевые слова — акустическое распознавание, автономное технологическое оборудование, ансамблевый алгоритм, эмпирическое разложение по модам.

Для цитирования: 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, EDN: VHOSZZ

For citation: Verzun N. A., Kolbanev M. O., Salieva A. R. Multi-agent ensemble algorithm for acoustic recognition of malfunctions of autonomous technological equipment. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 14–24 (In Russian). doi:10.31799/1684-8853-2025-3-14-24, EDN: VHOSZZ

Введение

Современные автономные системы, такие как беспилотные летательные аппараты, промышленные роботы и оборудование различных видов, играют ключевую роль в производственных процессах [1]. Эффективность и безопасность их применения зависят от своевременного выявления нарушений работоспособности. При этом диагностика, предусматривающая участие людей, зачастую просто невозможна и может быть заменена анализом акустических данных, которые позволяют обнаруживать ранние признаки

неисправностей без физического вмешательства в процесс функционирования систем [2].

В статье [3] показано, что обучение с подкреплением перспективно для применения в логистических системах, которые включают в себя и акустические системы распознавания. В настоящей статье предлагаются и исследуются конкретные технические решения, которые позволяют эффективно диагностировать неисправности в логистических системах, а именно, предлагается новый подход к акустическому распознаванию нарушений работоспособности автономно работающего технологического оборудования с ис-

пользованием многоагентного ансамблевого алгоритма на основе обучения с подкреплением, который обеспечивает высокую гибкость, масштабируемость и точность диагностики за счет изучения каждым агентом части характеристик акустических сигналов с последующей агрегацией полученных данных [4].

Структура системы акустического распознавания

Акустический сигнал в общем случае представляет собой смесь сигналов, которые вырабатываются диагностируемым оборудованием и его внешним окружением [5]. Звуковой сигнал, воспроизводимый оборудованием, воспринимается акустическим датчиком. Важно обеспечить точность записи сигнала, ослабить влияние шумов и искажений, сохраняя все ключевые особенности звука, поскольку от этого зависит корректность его анализа в дальнейшем [6]. Система акустического распознавания реализует обработку и классификацию акустических данных на основе ансамблевого алгоритма, объединяющего результаты, полученные от различных агентов. Используется комбинация нескольких специализированных агентов, каждый из которых фокусируется на определенном аспекте акустического сигнала. Для повышения точности и надежности распознавания учитываются:

- спектральные характеристики сигнала: частотный спектр, амплитуда и фаза звуковых волн, гармоники, — которые могут указывать на определенные типы звуков, такие как работающие механизмы или нарушения [7];
- временные паттерны: длительность звуковых событий, их последовательность и интервалы между ними, — что позволяет различать нор-

мальное функционирование оборудования от его отказов [8];

- информация о функционировании оборудования: условия эксплуатации оборудования, например, тип технологического процесса, специфику его работы и возможные источники помех, — что может помочь в более точной интерпретации акустических сигналов [9];

- особенности внешнего окружения: факторы окружающей среды, такие как уровень фонового шума, отражения звука от стен и других объектов, — что может повлиять на качество и точность распознавания звуковых сигналов [10].


Структура системы акустического распознавания показана на рис. 1.

Рассмотрим каждый компонент подробнее.

Предобработка сигнала. Выполняются:

- нормализация амплитуды — уравниваются степени громкости для устранения значительных перепадов амплитуды и улучшения качества обработки;
- удаление шума — применяются фильтры (например, полосовой фильтр) для удаления фоновых шумов и улучшения четкости полезного сигнала;
- сегментация сигнала — длинный сигнал делится на более короткие фрагменты для более точного анализа и локализации звуковых событий;
- извлечение важных характеристик — применяются такие методы, как мел-кепстральные коэффициенты для выделения речевых признаков, и спектрограммы для анализа частотных компонентов сигнала. Это позволяет получить набор признаков, который используется на следующих этапах [11].

Многоагентная система анализа состоит из специализированных агентов. Эти агенты используют методы машинного обучения и глубокого обучения, обученные на соответствующих типах данных [12]:



■ **Рис. 1.** Структура системы акустического распознавания

■ **Fig. 1.** The structure of the acoustic recognition system

— агент спектрального анализа изучает частотные характеристики сигнала, используя методы спектрального анализа и сверточные нейронные сети, специализируется на извлечении частотных особенностей, таких как тональные характеристики звука;

— агент временного анализа исследует временные закономерности сигнала, например паузы, изменение интенсивности, использует рекуррентные нейронные сети для анализа временной динамики, что важно для распознавания последовательных паттернов [13];

— агент анализа функционирования оборудования анализирует более высокоуровневые контекстные признаки сигнала, применяя трансформеры для захвата зависимостей между различными частями сигнала, что полезно для распознавания более сложных акустических событий, например фраз в речевом потоке;

— агент анализа внешнего окружения оценивает шумы, помехи и другие характеристики окружающей среды, чтобы учитывать их влияние на качество сигнала, применяет методы обработки сигналов для работы с низкокачественными или зашумленными данными [14].

Каждый агент использует специфические алгоритмы машинного обучения для анализа соответствующих аспектов сигнала.

Ансамблевый агрегатор принятия решения. Ансамблевая агрегация позволяет объединять результаты, полученные от всех агентов, для формирования общего решения [15]. Подобный подход нацелен на снижение вероятности пропуска критичных признаков нарушений и повышение общей эффективности системы мониторинга [16]. Для организации ансамбля используются:

— взвешенное голосование — каждый агент голосует за свое решение и каждому голосу присваивается вес в зависимости от точности данного агента; этот метод обеспечивает баланс между мнениями агентов с учетом их опыта, а также позволяет учитывать разнородность данных и повышать устойчивость системы к ошибкам;

— ансамблевые методы, основанные на идее объединения результатов нескольких моделей или алгоритмов для получения более точного и надежного результата; основные принципы ансамблевых методов: разнообразие — использование различных типов моделей или алгоритмов, независимость — минимизация корреляции между ошибками отдельных моделей, агрегация — эффективное объединение результатов отдельных моделей [17].

Принятие решений позволяет сделать окончательный вывод о состоянии оборудования. Модуль принимает выходные данные от агентов. Далее проводится нормализация данных для унификации их масштаба. После этого вы-

числяется степень уверенности каждого агента на основе метрики точности, полученной в процессе обучения. Затем осуществляется комбинирование результатов с использованием взвешенного голосования и принимается окончательное решение.

Алгоритм и математическая модель обучения агентов

Обучение агента заключается в выработке правильных решений о состоянии автономно работающего оборудования. При обучении агентов последовательно выполняются следующие шаги.

1. Инициализировать агентов случайными весами.

2. Для каждого обучающего примера:

- выполнить предобработку;
- пропустить через всех агентов;
- агрегировать результаты;
- вычислить ошибку;
- обновить веса агентов и агрегатора.

3. Повторять шаг 2 до сходимости.

Работа агентов в системе построена на базе глубокого обучения с подкреплением. В частности, для задач акустического распознавания звуковых сигналов может использоваться алгоритм глубоких Q-сетей (Deep Q-Network, DQN). Он эффективен для акустического распознавания звуковых сигналов с изменяющимися состояниями [18].

Агенты (см. рис. 1), решая свои задачи, выполняют следующие операции.

1. Выбор действия агентом. DQN эффективно обучает агента принимать решения в сложных средах, что делает его полезным для задач, где требуется многократное взаимодействие с системой, например для акустического распознавания с различными состояниями звуковых сигналов:

$$Q(s, a) \leftarrow Q(s, a) + \alpha(R + \gamma \max_{a'} Q(s', a') - Q(s, a)),$$

где $Q(s, a)$ — текущее значение Q-функции (оценка полезности) для состояния s и действия a ; α — скорость обучения, параметр от 0 до 1, который контролирует, насколько сильно обновляется значение; R — вознаграждение, полученное за выполнение действия a в состоянии s ; γ — коэффициент дисконтирования, отражает важность будущих наград; s' — следующее состояние после выполнения действия a в состоянии s ; $Q(s', a')$ — Q-значение для следующего состояния s' и действия a' ; $\max_{a'} Q(s', a')$ — максимальное значение Q-функции для всех возможных действий a' в следующем состоянии s' . Это оценка наилуч-

шего возможного действия в будущем. $Q(s, a) \leftarrow Q(s, a) \dots$ означает обновление старого значения Q -функции новым, более точным, на основе полученного опыта.

2. Функция потерь для обновления Q -функции. Функция потерь минимизирует разницу между текущими оценками и целевыми значениями, что позволяет агенту улучшать свои решения. Для расчета функции потерь применяется беллмановское уравнение для оптимизации стратегий в задачах с последовательными действиями, таких как управление звуковыми сигналами в реальном времени:

$$L = E \left[\left(R + \gamma \frac{\max_{a'} Q(s', a') - Q(s, a)}{a'} \right) \right],$$

где L — функция потерь; $E[\dots]$ — математическое ожидание. Данная функция минимизирует ошибку между предсказанной и фактической наградой, что позволяет агенту улучшать свои стратегии.

Результаты от отдельных агентов агрегируются в ансамбле, что помогает выбирать верные действия.

Ансамблевое решение. Для повышения устойчивости к шуму и случайным ошибкам отдельных агентов используется ансамблевый подход. Окончательное действие выбирается на основе моды

$$a_{ensemble} = \text{mode}(a_1, a_2, \dots, a_n),$$

где a_i — действие, выбранное i -м агентом, а n — число агентов. Использование моды позволяет учитывать решение большинства агентов, повышая надежность системы в условиях неопределенности.

Для ускорения обучения и повышения кооперации между агентами вводится механизм адаптивного распределения наград:

$$R_i = \begin{cases} R \times (1 + \lambda) \\ R \times (1 + \beta) \end{cases},$$

где R_i — награда i -го агента; R — общая награда; λ и β — коэффициенты усиления и ослабления соответственно (например, $\lambda = 0,1$, $\beta = -0,1$). Этот подход стимулирует агентов достигать консенсуса, а также поощряет решения, способствующие общим целям системы.

Для того чтобы не было заикливания в начале обучения, в нашем ансамбле предлагается использовать ϵ -жадную стратегию исследования. Она позволяет агентам исследовать новые стратегии в начале обучения, чтобы не застрять в локальных оптимумах. На поздних стадиях агенты могут больше полагаться на накоп-

ленные знания, что улучшает их долгосрочную производительность:

$$\epsilon_t = \max(\epsilon_{\min}, \epsilon_0 \times \delta^t),$$

где ϵ_t — значение epsilon на шаге t ; $\epsilon_{\min}$ — минимальное значение epsilon; ϵ_0 — начальное значение epsilon, а δ^t — коэффициент затухания.

Для того чтобы эффективно отслеживать среднюю награду без необходимости хранить все предыдущие значения, используем инкрементальное обновление среднего значения награды

$$\bar{R}_t = \bar{R}_{t-1} + \frac{1}{t}(R_t - \bar{R}_{t-1}),$$

где $\bar{R}_t$ — среднее значение награды на шаге t , а R_t — награда на шаге t .

Оценка качества распознавания

Тестирование алгоритма проводилось на различных типах оборудования для оценки его эффективности в распознавании аномалий. При этом для оценки качества распознавания использовались метрики [19]:

— точность (Precision) — показывает, какой процент всех предсказанных положительных значений действительно является положительным:

$$P = \frac{TP}{TP + FP} \times 100\%,$$

где TP (True Positives) — количество истинно положительных результатов, т. е. правильное распознавание нарушений; FP (False Positives) — количество ложноположительных результатов, т. е. ошибочное распознавание нарушений. Высокая точность означает, что алгоритм редко ошибается, предсказывая положительные значения;

— полнота (Recall) — показывает, какой процент из всех реальных положительных значений был правильно предсказан как положительные значения:

$$R = \frac{TP}{TP + FN} \times 100\%,$$

где FN (False Negatives) — количество ложноотрицательных результатов, т. е. нераспознанных нарушений. Высокая полнота означает, что алгоритм не пропускает положительные классы;

— F-мера — гармоническое среднее точности и полноты:

$$F = \frac{2PR}{P + R} \times 100\%;$$

— ложные срабатывания (False Positive Rate)

$$FPR = \frac{FP}{TP + FP + TN + FN} \times 100\%,$$

где TN (True Negatives) — количество истинно отрицательных результатов, т. е. правильное отсутствие нарушений.

Описание эксперимента

Цель эксперимента — проверить работоспособность и оценить эффективность многоагентного ансамблевого алгоритма для акустического распознавания нарушений работоспособности автономного технологического оборудования. Проектирование вычислительной системы, обеспечивающей заданное время отклика, в данной статье не рассматривается, что позволило использовать для проведения эксперимента доступную и относительно недорогую вычислительную систему.

Оборудование и материалы:

- компьютер (процессор Intel Core i5-8300H (4 ядра, 2.3–4.0 ГГц), 32 ГБ RAM, SSD-накопитель 1 ТБ) с установленным Python 3.4 и необходимыми библиотеками;
- набор данных MIMII;
- автономное технологическое оборудование для тестирования (опционально).

Специализированные библиотеки для Python:

- TensorFlow и PyTorch для построения и обучения нейронных сетей, включая модели для агентов;
- Stable Baselines3 для реализации алгоритмов обучения с подкреплением (в частности, DQN);
- Ray и RLlib для управления многоагентными системами, позволяют проводить распределенное обучение агентов и масштабируемую обработку данных;
- Librosa для обработки аудиоданных, включая функции анализа акустических сигналов, такие как формирование спектрограммы, извлечение частотных характеристик методом мел-кепстральных коэффициентов.

Исходные данные для обучения агентов.

Для обучения многоагентного ансамблевого алгоритма акустического распознавания неисправностей использовались акустические сигналы из тщательно отобранных открытых баз данных. Эти базы данных обеспечивают разнообразие сценариев и условий функционирования оборудования, что значительно повышает качество и универсальность обученной модели. Использовались следующие датасеты.

1. MIMII Dataset (Malfunctioning Industrial Machine Investigation and Inspection). Этот на-

бор данных является одной из наиболее популярных коллекций для исследований в области диагностики неисправностей промышленного оборудования. Он содержит аудиозаписи работы четырех типов оборудования: насосов, вентиляторов, клапанов и компрессоров. Для каждого типа представлены как записи нормального состояния, так и акустические сигналы, соответствующие различным типам неисправностей. Уникальность набора MIMII заключается в том, что он моделирует реальные производственные условия, включая фоновый шум, что делает его полезным для разработки алгоритмов, устойчивых к внешним акустическим помехам (*MIMII Dataset: Sound Dataset for Malfunctioning Industrial Machine Investigation and Inspection*. <https://zenodo.org/records/3384388>).

2. Industrial Sound Data for Anomalous Sound Detection (DCASE Challenge). Данный набор был специально разработан для задач обнаружения аномалий звуков в промышленной среде в рамках конкурсов серии DCASE. Коллекция охватывает широкий спектр устройств, таких как насосы, двигатели и компрессоры. Отличительной чертой этого набора является его фокус на реальных производственных условиях. Он включает звуки как нормальной работы оборудования, так и редкие, трудноуловимые акустические аномалии, что делает его незаменимым инструментом для повышения чувствительности алгоритмов к незначительным отклонениям в звуках (*Detection and Classification of Acoustic Scenes and Events*. <https://dcase.community/>).

3. ToyADMOS Dataset. Набор ToyADMOS был разработан специально для исследований в области обнаружения аномалий на примере звуков игрушечного промышленного оборудования. Хотя масштабы и физические характеристики таких устройств могут отличаться от крупного промышленного оборудования, их акустические сигналы представляют ценность для разработки алгоритмов. ToyADMOS содержит звуки нормальной и аномальной работы, что позволяет изучать характерные особенности, свойственные разным типам неисправностей, в условиях низкой интенсивности звука и минимального шума (*Dataset from Zenodo* (2020). <https://zenodo.org/records/4580270>).

Анализ результатов эксперимента

Результаты работы многоагентного ансамблевого алгоритма отражены в табл. 1, где приводятся показатели оценки эффективности распознавания неисправностей для различных типов оборудования и нарушений: точность, полнота, F1-мера и уровень ложных срабатываний. Эти метрики дают всестороннее представление о ка-

■ **Таблица 1.** Показатели оценки эффективности распознавания неисправностей для различных типов оборудования и нарушений
■ **Table 1.** Indicators for assessing the effectiveness of fault recognition for various types of equipment and malfunctions

Тип оборудования	Тип нарушения	Точность, %	Полнота, %	F1-мера, %	Ложные срабатывания, %
Насос	Вибрации	94	91	92	5
Насос	Трение	92	90	91	6
Вентилятор	Неравномерный шум	90	89	89	7
Компрессор	Низкочастотные колебания	91	88	89	6
Клапан	Аномальные вибрации	93	92	92	4
Компрессор	Высокочастотные шумы	89	87	88	8
Вентилятор	Перегрев (шум вентиляции)	92	90	91	5
Конвейер	Прерывания работы	95	93	94	4
Электродвигатель	Аномальные звуки	88	85	86	10
Генератор	Перегрев	91	89	90	5
Вибрационный насос	Шумы из-за износа	90	87	88	7
Редуктор	Неправильное положение	92	91	91	3
Компрессор	Увеличенный уровень шума	89	86	87	9
Гидравлическая система	Протечки	93	92	92	5
Оборудование для упаковки	Неисправность механизмов	90	88	89	8

честве работы алгоритма в условиях реального применения.


Алгоритм был протестирован на различных типах промышленного оборудования. Основные типы неисправностей, которые анализировались в рамках экспериментов:

– вибрации (аномальные или аномально высокие);

– неравномерные или высокочастотные шумы;
– прерывания работы механизмов;
– протечки, трение и перегрев.

Групповая столбчатая диаграмма (рис. 2) сравнивает выбранные метрики для каждого типа оборудования.

Система продемонстрировала высокие результаты по всем метрикам. Точность и полнота



■ **Рис. 2.** Сравнение метрик для каждого типа оборудования
■ **Fig. 2.** Comparison of metrics for each type of equipment

большинства тестируемых устройств находятся в диапазоне 88–95 %, что свидетельствует о высокой надежности алгоритма. Средние значения F1-меры также подтверждают сбалансированную работу алгоритма, особенно в условиях обработки сложных звуковых данных.

Типы оборудования и точность обнаружения

Насосы. Алгоритм показал высокую эффективность в обнаружении вибраций и трения. Средняя F1-мера составляет 91,5 %, что отражает способность системы успешно распознавать как нормальные, так и неисправные состояния.

Вентиляторы. Неравномерные шумы и шумы, вызванные перегревом, распознавались с точностью 92 %, при этом уровень ложных срабатываний удерживался на уровне 5–7 %.

Компрессоры. Обнаружение низко- и высокочастотных шумов оказалось более сложной задачей, с точностью 89–91 %, что связано с высокой вариативностью акустических сигналов компрессоров.

Клапаны. Здесь система показала наилучшие результаты: точность 93 %, полнота 92 % и минимальные ложные срабатывания (4 %).

Уровень ложных срабатываний

Ложные срабатывания остались в пределах допустимых значений, не превышая 10 % даже в самых сложных случаях (например, для электродвигателей и компрессоров с высоким уровнем шума). Это говорит о том, что алгоритм обладает высокой устойчивостью к ошибкам, связанным с шумами окружающей среды.

Особые сценарии и устройства

Конвейеры и гидравлические системы продемонстрировали максимальную точность классификации (93–95 %), что объясняется более однородными акустическими характеристиками этих типов оборудования.

Электродвигатели и оборудование для упаковки показали более низкие результаты (средняя F1-мера 86–89 %) из-за сложности сигналов и высокой чувствительности к фоновым шумам.

Итог эксперимента

Многоагентный ансамблевый алгоритм продемонстрировал высокую эффективность в обнаружении неисправностей для широкого спектра оборудования. Наилучшие результаты достигнуты при работе с насосами, клапанами и гидравлическими системами, где удалось минимизировать ложные срабатывания и добиться высокой точности.

Несмотря на небольшое снижение точности для сложных сценариев, таких как аномальные звуки электродвигателей или высокочастотные шумы компрессоров, система сохраняет уверенность в классификации, обеспечивая значительное преимущество перед традиционными

подходами. Такой уровень производительности делает алгоритм пригодным для внедрения в реальные производственные системы, где требуются высокая надежность и точность диагностики.

Анализ нагрузки на компьютер и время выполнения алгоритма

Для успешного внедрения многоагентного ансамблевого алгоритма в реальные производственные системы важно учитывать вычислительную нагрузку, которую он создает на оборудование. Основные параметры, характеризующие нагрузку, включают загрузку центрального процессора (CPU), использование оперативной памяти (RAM) и время выполнения задачи. Эти показатели варьируются в зависимости от типа оборудования и характера неисправности, которые анализирует алгоритм. В табл. 2 и на рис. 3 представлены основные показатели нагрузки на компьютер и время выполнения алгоритма.

Загрузка CPU указывает на процент использования центрального процессора во время выполнения алгоритма. Например, для распознавания прерываний работы на конвейере наблюдается загрузка 65 %.

Загрузка RAM отображает объем оперативной памяти, используемой алгоритмом. В случае электродвигателя, например, используется 180 МБ.


Время выполнения — показатель времени, необходимого для выполнения алгоритма для каждого типа нарушения. Например, на распознавание шумов из-за износа вибрационного насоса уходит 3,2 с.

Потребление оперативной памяти отражает объем данных, который должен быть обработан алгоритмом одновременно. Наибольшее потребление памяти зафиксировано для электродвигателей (180 МБ) и оборудования для упаковки (175 МБ), что связано с большим числом характеристик, учитываемых при анализе аномалий. Наименьший объем памяти использовался для генератора при анализе перегрева (140 МБ) и гидравлической системы при обнаружении протечек (145 МБ). Эти данные подтверждают, что использование RAM остается в пределах, допустимых для большинства современных компьютерных систем, что делает алгоритм применимым даже на оборудовании среднего уровня.

Загрузка CPU характеризует интенсивность вычислительных операций, выполняемых алгоритмом. Наибольшая загрузка наблюдается при анализе сложных или многосоставных акустических сигналов, таких как аномальные звуки электродвигателей (70 %) и неисправности механизмов упаковочного оборудования (71 %).


■ **Таблица 2.** Нагрузка на компьютер и время выполнения■ **Table 2.** Computer load and execution time

Тип оборудования	Тип нарушения	Загрузка CPU, %	Загрузка RAM, МБ	Время выполнения, с
Конвейер	Прерывания работы	65	150	2,5
Электродвигатель	Аномальные звуки	70	180	3,0
Генератор	Перегрев	60	140	2,8
Вибрационный насос	Шумы из-за износа	68	160	3,2
Редуктор	Неправильное положение	64	155	2,7
Компрессор	Увеличенный уровень шума	69	170	3,1
Гидравлическая система	Протечки	66	145	2,9
Оборудование для упаковки	Неисправность механизмов	71	175	3,3

■ **Рис. 3.** Сравнение загрузки CPU, RAM и времени выполнения по типам оборудования■ **Fig. 3.** Comparison of CPU load, RAM usage, and execution time across equipment types

Минимальная нагрузка зафиксирована при обработке сигналов редуктора с некорректным положением (64 %) и конвейера с прерываниями работы (65 %). Такая вариативность обусловлена сложностью извлечения признаков из сигналов различной природы и необходимостью обработки большого объема данных для аномалий высокой сложности.

Время выполнения — один из важнейших факторов, особенно для систем реального времени. Зависимость времени выполнения алгоритма от загрузки CPU иллюстрирует рис. 4. Самое быстрое выполнение наблюдается при распознавании прерываний работы на конвейере (2,5 с) и неправильного положения редуктора (2,7 с). Максимальное время выполнения потребовалось для анализа шумов из-за износа вибра-

■ **Рис. 4.** Зависимость времени выполнения от загрузки CPU■ **Fig. 4.** Dependence of execution time on CPU load

ционного насоса (3,2 с) и неисправности механизмов упаковочного оборудования (3,3 с).

В случае внедрения описанного алгоритма на практике рекомендуется применение вычислительной системы, параметры которой обеспечат время отклика, приемлемое для соответствующей предметной области. В частности, возможно применение аппаратного ускорения (GPU/TPU). Время реакции системы также может быть дополнительно оптимизировано за счет уменьшения сложности моделей агентов (например, замены традиционной сверточной нейронной сети на MobileNet) и параллелизации вычислений.

Заключение

В рамках проведенного исследования был разработан и протестирован многоагентный ансамблевый алгоритм для акустического распознава-

ния нарушений работоспособности автономного технологического оборудования. Многоагентный алгоритм базируется на интеграции нескольких специализированных агентов, каждый из которых анализирует определенные аспекты акустического сигнала, а также на использовании механизмов ансамблевого обучения для повышения точности и надежности системы.

Основным элементом новизны работы является сочетание многоагентного подхода с адаптивными ансамблевыми методами, которые учитывают индивидуальные сильные стороны каждого агента и динамически изменяют их вес при принятии решений. Введенные механизмы регуляризации и прогрессивного изменения коэффициентов, управляющих обучением, позволяют снизить вероятность переобучения и повысить устойчивость системы к внешним воздействиям. Кроме того, использование инновационных методов обработки сигналов, таких как динамическое дисконтирование наград и учет неопределенности через UCB (Upper Confidence Bound), вносит вклад в развитие алгоритмов обнаружения аномалий.

Разработанный алгоритм может быть эффективно применен в системах мониторинга состояния автономного технологического оборудования [20]. Он обеспечивает высокую точность распознавания аномальных звуков, что критически важно для своевременного выявления неисправностей и предотвращения аварий. Система также адаптируется к различным условиям эксплуатации и способна обрабатывать акустические данные в реальном времени, что делает ее подходящей для применения в промышленных условиях, где требуется минимизация времени простоя оборудования.

Тестирование алгоритма выявило несколько ограничений, которые требуют дальнейшей разработки:

— снижение точности в условиях высоких уровней шума. Внешние акустические помехи, особенно схожие с частотными характеристиками неисправностей, приводят к повышению числа ложных срабатываний. Это указывает на необходимость разработки более устойчивых методов фильтрации и разделения сигналов;

— ограничения при анализе редких или новых типов неисправностей. Отсутствие достаточного количества тренировочных данных для таких случаев ограничивает возможности системы. Дальнейшие исследования могут быть направлены на использование методов генеративного обучения для синтеза данных;

— высокие вычислительные требования. Многоагентная структура, хотя и обеспечивает высокий уровень точности, требует значительных ресурсов, что делает ее неприменимой для оборудования с низкой производительностью. В этом направлении целесообразно исследовать механизмы оптимизации вычислений и аппаратных реализаций.

Для обработки более сложных сигналов (например, высокочастотных шумов) целесообразно использовать оптимизированные библиотеки или вычислительные ускорители, такие как GPU или TPU. Встроенные механизмы регуляции параметров алгоритма (например, снижение разрешения спектрограммы) могут дополнительно уменьшить вычислительную нагрузку при минимальных потерях в точности.

Несмотря на существующие ограничения, разработанный многоагентный ансамблевый алгоритм демонстрирует практическую значимость и потенциал для применения в промышленных системах диагностики. Дальнейшие усилия по устранению выявленных недостатков и адаптации системы к более широкому спектру задач позволят расширить ее функциональные возможности и применимость в условиях реальной эксплуатации.

Литература

1. Zonzini F., Bogomolov D., Dhamija T., Testoni N., De Marchi L., Marzani A. Deep learning approaches for robust time of arrival estimation in acoustic emission monitoring. *Sensors*, 2022, vol. 22, no. 3, Article 1091. doi.org/10.3390/s22031091
2. Митр Д. В. Распознавание типа наземной техники по акустическому сигналу на основе алгоритма с временной кодировкой. *Будущее машиностроения России: сборник докладов XV Всероссийской конференции молодых ученых и специалистов (с международным участием)*, Москва, 21–24 сентября 2022 г. М., 2023, т. 2, с. 234–236.
3. Верзун Н. А., Колбанев М. О., Салиева А. Р. Анализ перспектив обучения умных автономных логи-

стических систем на основе оптимизации функции ценности. *Известия СПбГЭТУ «ЛЭТИ»*, 2024, т. 17, № 10, с. 28–39. doi:10.32603/2071-8985-2024-17-10-28-39

4. Yang Z., Ma N., Yao Y. A survey on cooperative control of multi-agent systems. *Proceedings of 2023 2nd International Conference on Artificial Intelligence, Human-Computer Interaction and Robotics (AIHCIR)*, 2023, pp. 501–515. doi.org/10.1109/AIHCIR61661.2023.00090
5. Kalech M., Khalastchi E. On fault detection and diagnosis in robotic systems. *ACM Computing Surveys*, 2018, vol. 51, no. 1, Article 9. doi.org/10.1145/3146389
6. Wang J., Zhou J., Chen X. *Data-Driven Fault Detection and Reasoning for Industrial Monitoring*. Springer

- er Singapore, 2022. 264 p. doi.org/10.1007/978-981-16-8044-1
7. Jombo G., Zhang Y. Acoustic-based machine condition monitoring — Methods and challenges. *Eng.*, 2023, vol. 4, no. 1, pp. 47–79. doi.org/10.3390/eng4010004
 8. Бережнов Н. И., Сирота А. А. Универсальный алгоритм улучшения изображений с использованием глубоких нейронных сетей. *Вестник ВГУ. Серия: Системный анализ и информационные технологии*, 2022, № 2, с. 81–92. doi:10.17308/sait/1995-5499/2022/2/81-92
 9. Харламов А. А. Анализ текстов с использованием искусственных нейронных сетей на основе нейронных элементов с временной суммацией сигналов (часть 1). *Речевые технологии*, 2023, № 1, с. 87–99. <https://speechtechnology.ru/assets/files/1-2023.pdf> (дата обращения: 20.02.2025).
 10. Mastella M., Thiemens T., Cicca E. Texture recognition using a biologically plausible spike phase-locked loop model for spike train frequency decomposition. *arXiv preprint*, 2024. arXiv:2403.09723. doi:10.48550/arXiv.2403.09723
 11. Marin O., Sens P., Briot J.-P., Guessoum Z. Towards adaptive fault tolerance for distributed multi-agent systems. *Proceedings of the 4th European Seminar on Advanced Distributed Systems (ERSADS '2001)*, 2001, pp. 195–201.
 12. Jaros R., Byrtus R., Dohnal J., Danys L., Baros J., Koziorek J., Zmij P., Martinek R. Advanced signal processing methods for condition monitoring. *Archives of Computational Methods in Engineering*, 2022, vol. 30, no. 1. doi:10.1007/s11831-022-09834-4
 13. Belhadi A., Djenouri Y., Srivastava G., Lin J. C.-W. Reinforcement learning multi-agent system for faults diagnosis of microservices in industrial settings. *Computer Communications*, 2021, vol. 177, pp. 213–219. doi:10.1016/j.comcom.2021.07.010
 14. Liu Y., Ding W., Feng Y., Guo Y. Ensembled mechanical fault recognition system based on deep learning algorithm. *Journal of Vibroengineering*, 2021, vol. 23, no. 6, pp. 1318–1331. doi:10.21595/jve.2021.21944
 15. Maldonado D., Cruz E., Torres J. A., Cruz P. J., Benitez S. D. P. G. Multi-agent systems: A survey about its components, framework and workflow. *IEEE Access*, 2024, vol. 12, pp. 80950–80975. doi:10.1109/ACCESS.2024.3409051
 16. Shahid M. H. B., Azim A. Ensemble method for fault detection & classification in transmission lines using ML. *Proceedings of the 2023 IEEE International Systems Conference (SysCon)*, 2023, pp. 1–7. doi:10.1109/SysCon53073.2023.10131138
 17. Sutton R. S., Barto A. G. (2014–2015). *Reinforcement Learning: An Introduction* (2nd ed.). Cambridge, MIT Press, 2014–2015. 338 p.
 18. Lattimore T., Szepesvári C. *Bandit Algorithms*. Draft, 2018. 513 p.
 19. Powers D. M. W. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness, and correlation. *Journal of Machine Learning Technologies*, 2011, vol. 2, no. 1, pp. 2229–3981. doi:10.9735/2229-3981
 20. Салиева А. Р., Верзун Н. А., Колбанев М. О. Оптимизация стратегии в алгоритмах обучения с подкреплением в логистических системах принятия решений. *Известия СПбГЭТУ «ЛЭТИ»*, 2025, т. 18, № 3, с. 65–77. doi: 10.32603/2071-8985-2025-18-3-65-77

UDC 004.896

doi:10.31799/1684-8853-2025-3-14-24

EDN: VHOSZZ

Multi-agent ensemble algorithm for acoustic recognition of malfunctions of autonomous technological equipment

N. A. Verzun^{a,b}, PhD, Tech., Associate Professor, orcid.org/0000-0002-0126-2358, verzun.n@unecon.ru

M. O. Kolbanev^{a,b}, Dr. Sc., Tech., Professor, orcid.org/0000-0003-4825-6972

A. R. Salieva^a, Post-Graduate Student, orcid.org/0009-0001-9519-5773

^aSaint-Petersburg Electrotechnical University «LETI», 5, Prof. Popov St., 197376, Saint-Petersburg, Russian Federation

^bSaint-Petersburg State University of Economics, 30-32, Griboedov canal Emb., 191023, Saint-Petersburg, Russian Federation

Introduction: In highly automated production, traditional methods of diagnostics of process equipment operation based on visual inspection or mechanical sensors are often insufficient. Taking into account autonomous modes of equipment using artificial intelligence, automatic monitoring systems that use acoustic data, capable of signaling faults without interfering with the operation process, are becoming increasingly important. **Purpose:** To develop a multi-agent ensemble algorithm for acoustic recognition capable of identifying various types of disturbances in the operation of autonomous technical systems with an accuracy of at least 90%, an F1-measure of ≥ 0.85 . **Results:** We propose a new approach to acoustic recognition of faults in autonomous process equipment based on a multi-agent ensemble algorithm. We develop the architecture of a multi-agent system, including four specialized agents that analyze various parameters of acoustic signals: 1) a spectral analysis agent evaluates changes in the frequency content of the acoustic signal, identifying abnormal oscillations characteristic of mechanical damage and malfunctions; 2) a temporal analysis agent tracks time patterns of acoustic data, analyzing changes in the amplitude and duration of signals, which allows identifying short-term failures and irregular noises; 3) an equipment performance analysis agent correlates acoustic data with the equipment operating modes, identifying deviations from normal

operation; 4) an external environment analysis agent takes into account external noise factors and filters them, increasing the accuracy of diagnostics by eliminating extraneous sounds. The agents are implemented and trained using machine and deep learning methods. As part of the study, we conduct an experiment in which the effectiveness of the proposed algorithm is assessed. The accuracy of fault recognition has reached at least 90%. The conducted study shows that the use of a multi-agent approach makes it possible to increase the reliability of diagnostics by combining the results of various analytical models. **Practical relevance:** The program code implementing the ensemble recognition algorithm can be used to diagnose a wide range of autonomous systems.

Keywords – acoustic recognition, autonomous technological equipment, ensemble algorithm, empirical mode decomposition.

For citation: Verzun N. A., Kolbanov M. O., Salieva A. R. Multi-agent ensemble algorithm for acoustic recognition of malfunctions of autonomous technological equipment. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 14–24 (In Russian). doi:10.31799/1684-8853-2025-3-14-24, EDN: VHOSZZ

References

- Zonzini F., Bogomolov D., Dhamija T., Testoni N., De Marchi L., Marzani A. Deep learning approaches for robust time of arrival estimation in acoustic emission monitoring. *Sensors*, 2022, vol. 22, no. 3, Article 1091. doi.org/10.3390/s22031091
- Mitr D. V. Recognition of ground equipment type by acoustic signal based on time-encoded algorithm. *Sbornik dokladov XV Vserossiyskoy konferencii molodykh uchyonykh i specialistov (s mezhdunarodnym uchastiem) "Budushchee mashinostroeniya Rossii"* [Proc. XV All-Russian Conf. "The future of Russian engineering"]. Moscow, 2023, vol. 2, pp. 234–236 (In Russian).
- Verzun N. A., Kolbanov M. O., Salieva A. R. Analysis learning prospects of smart autonomous logistics systems based on value function optimization. *Izvestiya SPbGETU "LETI"*, 2024, vol. 17, no. 10, pp. 28–39 (In Russian). doi:10.32603/2071-8985-2024-17-10-28-39
- Yang Z., Ma N., Yao Y. A survey on cooperative control of multi-agent systems. *Proceedings of 2023 2nd International Conference on Artificial Intelligence, Human-Computer Interaction and Robotics (AIHCIR)*, 2023, pp. 501–515. doi.org/10.1109/AIHCIR61661.2023.00090
- Kalech M., Khalastchi E. On fault detection and diagnosis in robotic systems. *ACM Computing Surveys*, 2018, vol. 51, no. 1, Article 9. doi.org/10.1145/3146389
- Wang J., Zhou J., Chen X. *Data-Driven Fault Detection and Reasoning for Industrial Monitoring*. Springer Singapore, 2022. 264 p. doi.org/10.1007/978-981-16-8044-1
- Jombo G., Zhang Y. Acoustic-based machine condition monitoring – Methods and challenges. *Eng.*, 2023, vol. 4, no. 1, pp. 47–79. doi.org/10.3390/eng4010004
- Berezhnov N. I., Sirota A. A. Universal image enhancement algorithm using deep neural networks. *Proceedings of VSU. Series: Systems Analysis and Information Technologies*, 2022, no. 2, pp. 81–92 (In Russian). doi:10.17308/sait/1995-5499/2022/2/81-92
- Kharlamov A. A. Text analysis using artificial neural networks based on neural-like elements with time summation of signals (part 1). *Rechevye tekhnologii*, 2023, no. 1, pp. 87–99. Available at: <https://speechtechnology.ru/assets/files/1-2023.pdf> (accessed 20 February 2025) (In Russian).
- Mastella M., Thiemens T., Cicca E. Texture recognition using a biologically plausible spike phase-locked loop model for spike train frequency decomposition. *arXiv preprint*, 2024. arXiv:2403.09723. doi:10.48550/arXiv.2403.09723
- Marin O., Sens P., Briot J.-P., Guessem Z. Towards adaptive fault tolerance for distributed multi-agent systems. *Proceedings of the 4th European Seminar on Advanced Distributed Systems (ERSADS '2001)*, 2001, pp. 195–201.
- Jaros R., Byrtus R., Dohnal J., Danyš L., Baros J., Koziorek J., Zmij P., Martinek R. Advanced signal processing methods for condition monitoring. *Archives of Computational Methods in Engineering*, 2022, vol. 30, no. 1. doi:10.1007/s11831-022-09834-4
- Belhadi A., Djenouri Y., Srivastava G., Lin J. C.-W. Reinforcement learning multi-agent system for faults diagnosis of microservices in industrial settings. *Computer Communications*, 2021, vol. 177, pp. 213–219. doi:10.1016/j.comcom.2021.07.010
- Liu Y., Ding W., Feng Y., Guo Y. Ensembled mechanical fault recognition system based on deep learning algorithm. *Journal of Vibroengineering*, 2021, vol. 23, no. 6, pp. 1318–1331. doi:10.21595/jve.2021.21944
- Maldonado D., Cruz E., Torres J. A., Cruz P. J., Benitez S. D. P. G. Multi-agent systems: A survey about its components, framework and workflow. *IEEE Access*, 2024, vol. 12, pp. 80950–80975. doi:10.1109/ACCESS.2024.3409051
- Shahid M. H. B., Azim A. Ensemble method for fault detection & classification in transmission lines using ML. *Proceedings of the 2023 IEEE International Systems Conference (SysCon)*, 2023, pp. 1–7. doi:10.1109/SysCon53073.2023.10131138
- Sutton R. S., Barto A. G. *Reinforcement Learning: An Introduction* (2nd ed.). Cambridge, MIT Press, 2014–2015. 338 p.
- Lattimore T., Szepesvári C. *Bandit Algorithms*. Draft, 2018. 513 p.
- Powers D. M. W. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness, and correlation. *Journal of Machine Learning Technologies*, 2011, vol. 2, no. 1, pp. 2229–3981. doi:10.9735/2229-3981
- Salieva A. R., Verzun N. A., Kolbanov M. O. Strategy optimization in reinforcement learning algorithms in logistic decision-making systems. *Izvestiya SPbGETU "LETI"*, 2025, vol. 18, no. 3, pp. 65–77. doi:10.32603/2071-8985-2025-18-3-65-77