

Сравнение алгоритмов обучения с подкреплением и многоагентного ансамблевого алгоритма в задачах акустического распознавания

Н. А. Верзун¹, М. О. Колбанев², А. Р. Салиева³, К. Н. Егоров⁴

Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)

¹verzun.n@unecon.ru, ²mokolbanev@mail.ru,
³rustamovna.a3@gmail.com, ⁴egorov.kirill.stav@yandex.ru

Аннотация. Акустическая диагностика неисправностей позволяет своевременно предотвращать сбои в работе, аварии и снизить эксплуатационные затраты автономно работающего оборудования. Проводится сравнительный анализ двух подходов к акустическому распознаванию неисправности оборудования: алгоритма на основе обучения с подкреплением и многоагентного ансамблевого метода. Апробация обеих разработанных алгоритмов проведена с использованием идентичных данных из базы MIMF, содержащей аудиозаписи работы промышленного оборудования. Результаты демонстрируют, что алгоритм на базе обучения с подкреплением достигает более высокой скорости обработки и точности распознавания неисправностей, тогда как многоагентный ансамблевый алгоритм обеспечивает устойчивость к шумам. Выбор конкретного метода зависит от требований к скорости, ресурсам и условиям эксплуатации оборудования.

Ключевые слова: акустическое распознавание; обучение с подкреплением; многоагентные системы; диагностика оборудования; ансамблевые алгоритмы

I. ВВЕДЕНИЕ

В современных промышленных системах востребованы автоматизированные методы мониторинга, способные обнаруживать неисправности и сбои в работе автономно функционирующего оборудования в режиме реального времени. К их числу, в частности, относят методы акустического распознавания, основанные на обучении с учителем и применяющие метод опорных векторов (Support Vector Machine, SVM) или решающих деревьев [1]. Однако зачастую они недостаточно точны в условиях шума и динамически меняющихся условий эксплуатации оборудования. В связи с этим актуальна разработка альтернативных методов диагностики состояния работающего оборудования. В настоящем исследовании предлагается для решения данной задачи использовать обучение с подкреплением (Reinforcement Learning, RL) и ансамблевые алгоритмы, которые уже показали значительный прогресс в подобных задачах акустического распознавания [2, 3].

Цель проводимого исследования сравнить эффективность двух подходов к акустическому распознаванию:

- RL-алгоритма, оптимизированного для классификации состояний оборудования на основе спектральных признаков акустических сигналов, вырабатываемых в процессе функционирования оборудования [4];
- многоагентного ансамблевого алгоритма (Multi-Agent Ensemble Algorithm for Recognition, MAAR), объединяющего нескольких агентов, каждый из которых нацелен на анализ определенной характеристики акустического сигнала [5].

II. ПОДХОДЫ К ПОСТРОЕНИЮ СИСТЕМ АКУСТИЧЕСКОГО РАСПОЗНАВАНИЯ

В рамках предыдущих исследований [6] были разработаны и экспериментально апробированы два метода акустической диагностики: алгоритм на основе обучения с подкреплением и многоагентный ансамблевый подход. Оба метода продемонстрировали высокую эффективность в задачах классификации неисправностей, однако их архитектурные и функциональные различия требуют сравнительного анализа для определения подходящих сценариев применения

A. Алгоритм на основе обучения с подкреплением

Обучение агента проводилось с использованием Deep Q-Network (DQN). Данный метод позволяет агенту обучаться на основе взаимодействия со средой, где он получает обратную связь через награды за правильные действия. Благодаря этому подходу, агент способен адаптироваться к изменениям в данных, что особенно важно в задачах акустического распознавания, где характеристики сигналов могут варьироваться в зависимости от условий эксплуатации [8].

Архитектура RL-агента включает следующие компоненты:

- Состояния. Вектор признаков, извлеченных из акустического сигнала: амплитудный спектр, мел-частотные кепстральные коэффициенты (Mel-Frequency Cepstral Coefficients, MFCC).
- Действия. Классификация состояний оборудования. Например, рассматривается два состояния: нормальное, неисправное.

- Награда. Функция, комбинирующая точность классификации и своевременность обнаружения дефектов [7].

Архитектура системы акустического распознавания для данного подхода показана на рис. 1.




Рис. 1. Архитектура системы акустического распознавания на основе обучения с подкреплением

В. Многоагентный ансамблевый алгоритм

Архитектура системы акустического распознавания для данного подхода показана на рис.2 и включает четырех агентов:

- Агент временного анализа – идентифицирует временные паттерны в динамике сигнала.
- Агент контекстного анализа – коррелирует данные с режимами работы оборудования.

- Агент анализа окружения – фильтрует внешние шумы.
- Агент спектрального анализа – выделяет частотные особенности акустического сигнала.

Ансамблевый подход реализуется путем агрегации результатов работы агентов с применением взвешенного голосования, что снижает риск ошибок [9].




Рис. 2. Архитектура многоагентного ансамблевого алгоритма акустического распознавания

III. СРАВНИТЕЛЬНЫЙ АНАЛИЗ РАБОТЫ АЛГОРИТМОВ АКУСТИЧЕСКОГО РАСПОЗНАВАНИЯ

Для проверки работоспособности алгоритмов (программ) проводилась их апробация с использованием готовых аудиофайлов (в формате wav), которые брались из открытой базы МИИП [10]. Использовали 1000 аудиосэмплов содержащих акустические сигналы, вырабатываемые в процессе функционирования оборудования: насосов, вентиляторов, клапанов и компрессоров. Типы неисправностей: вибрации, трение, перегрев, аномальные шумы.

А. Метрики

Для анализа качества акустического распознавания применяли метрики [11]:

- точность (accuracy) – доля правильных предсказаний модели относительно общего числа предсказаний.

- точность (precision) – доля правильно предсказанных положительных классов относительно всех предсказанных положительных классов.
- полнота (recall) – доля правильно предсказанных положительных классов относительно всех реальных положительных классов.
- F1-мера – среднее гармоническое между precision и recall, используется для балансировки этих двух метрик.
- Время отклика – интервал между получением сигнала и выводом результата.

Для анализа оценки вычислительной сложности алгоритмов (программ) применяли метрики: загрузка CPU и RAM, которые измерялись с помощью библиотеки psutil Python.

В. Результаты эксперимента

Показатели вычислительной нагрузки с детализацией по компонентам MAAR сведены в табл. I.

ТАБЛИЦА I. СРАВНЕНИЕ МЕТРИК ВЫЧИСЛИТЕЛЬНОЙ НАГРУЗКИ

Параметр	RL-алгоритм	MAAR (с детализацией по агентам)
Загрузка CPU	70%	Спектральный анализ: 20%
		Временной анализ: 18%
		Контекстный анализ: 15%
		Анализ окружения: 12%
Загрузка RAM	150МБ	Общая: 160 МБ
		Спектральный агент: 50 МБ
		Временной агент: 45 МБ
		Контекстный агент: 40 МБ
		Анализ окружения: 25 МБ

Результат акустического распознавания на одном наборе данных (аудиосэмплов) дал следующие результаты – табл. II.

ТАБЛИЦА II. СРАВНЕНИЕ МЕТРИК РАСПОЗНАВАНИЯ ДЛЯ РАЗЛИЧНЫХ ТИПОВ ОБОРУДОВАНИЯ

Тип оборудования и неисправности	Метрика	RL-алгоритм	MAAR
Насос вибрация	accuracy	95%	93%
	precision	93%	91%
	recall	92%	89%
	F1-мера	92.5%	90%
Вентиляторы неравномерный шум	accuracy	93%	91%
	precision	91%	88%
	recall	89%	86%
	F1-мера	90%	87%
Компрессоры низкочастотные колебания	accuracy	92%	90%
	precision	90%	87%
	recall	88%	85%
	F1-мера	89%	86%
Клапаны аномальные вибрации	accuracy	96%	94%
	precision	94%	92%
	recall	93%	90%
	F1-мера	93.5%	91%
Средние значения все типы оборудования и неисправностей	accuracy	94.5%	92%
	precision	92%	90%
	recall	90%	88%
	F1-мера	91%	89%
Среднее время отклика	-	0.25 сек	2.8 сек

Точность.

- RL-алгоритм показывает более высокую точность на оборудовании с четкими спектральными паттернами, например, для клапанов (96 % accuracy). Это объясняется тем, что алгоритм ориентирован на анализ MFCC и амплитудного спектра, что позволяет эффективно выделять периодические аномалии.
- MAAR демонстрирует стабильность в условиях высокого шума, например, для компрессоров с низкочастотными колебаниями (90 % accuracy). Фильтрация внешних помех агентом анализа окружения снижает количество ложных срабатываний до 7 %, тогда как у RL этот показатель составляет 5 %.

Скорость.

- RL-алгоритм обрабатывает сигналы практически в реальном времени (0.25 сек), что критично для

систем, где недопустима задержка, например, при мониторинге турбин.

- MAAR требует больше времени на обработку (2.8 сек) из-за работы четырех агентов и сложной агрегации результатов. Такой подход оправдан для задач, требующих глубокой аналитики, например, прогнозирования износа оборудования.

Ресурсы.

- RL-алгоритм потребляет меньше оперативной памяти (150 МБ), поскольку использует единую модель, что делает его удобным для систем с ограниченными ресурсами.
- MAAR требует 160 МБ RAM, но распределяет нагрузку между агентами. Например, спектральный агент (50 МБ) выполняет наиболее ресурсоемкие задачи, тогда как агент анализа окружения (25 МБ) работает с минимальными затратами.

IV. ЗАКЛЮЧЕНИЕ

Результаты проведенных экспериментов показали эффективность обоих разработанных алгоритмов при обнаружении неисправностей и сбоев в работе автономно функционирующего оборудования. Выбор конкретного метода для применения на практике зависит от требований к скорости классификации, потребляемым ресурсам и условиям эксплуатации оборудования.

По результатам сравнительного анализа значений метрик, полученных в ходе эксперимента, можно сформулировать следующие рекомендации по использованию подходов к акустическому распознаванию неисправностей:

- RL-алгоритм целесообразно применять для систем, где приоритетом являются скорость принятия решений и минимум затрачиваемых ресурсов. Например, это могут быть встроенные системы на производственных линиях.
- MAAR предпочтителен в условиях высокого уровня шума и в случае диагностики разнородного оборудования. Беспилотный транспорт, роботизированные комплексы.

Дальнейшее развитие алгоритмов может включать: оптимизацию MAAR для снижения времени выполнения, интеграцию RL-алгоритма с методами фильтрации шумов.

СПИСОК ЛИТЕРАТУРЫ

- [1] 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. P. 2446–2455. DOI: 10.1109/TII.2019.2901729.
- [2] Tian K., Chi Y., Duo B., Yuan X. Hybrid Offline-Online Design for Reconfigurable Intelligent Surface Aided UAV Communication // IEEE Communications Letters. 2023. Vol. 27, no. 5. P. 1372–1376. DOI: 10.1109/LCOMM.2023.3255241.
- [3] 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. Art. 1091. DOI: 10.3390/s22031091.

- [4] Ranjan S., Chakraborty R. Reinforcement Learning based Data Augmentation for Noise Robust Speech Emotion Recognition // Proc. of Interspeech. 2024. P. 1040–1044. DOI: 10.21437/Interspeech.2024-921.
- [5] Liu Y., et al. Ensembled Mechanical Fault Recognition System Based on Deep Learning Algorithm // Journal of Vibroengineering. 2021. Vol. 23, no. 6. P. 1318–1331.
- [6] Верзун Н.А., Колбанёв М.О., Салиева А.Р. Анализ перспектив обучения умных автономных логистических систем. // Известия СПбГЭТУ «ЛЭТИ», 2024, 17(10). С. 28–39.
- [7] Yang Z., Ma N., Yao Y. A Survey on Cooperative Control of Multi-Agent Systems // Proc. of AIHCIR. 2023. P. 501–515.
- [8] Lattimore T., Szepesvári C. Bandit Algorithms. 2018. arXiv:1802.09127.
- [9] Shahid M.H.B., Azim A. Ensemble Method for Fault Detection & Classification in Transmission Lines Using ML // IEEE SysCon. 2023. P. 1–7.
- [10] MIMII Dataset: Sound Dataset for Malfunctioning Industrial Machine Investigation and Inspection. Zenodo. URL: <https://zenodo.org/records/3384388> (дата обращения: 05.03.2025)
- [11] Powers D.M.W. Evaluation: From Precision, Recall and F-measure to ROC, Informedness, Markedness, and Correlation // Journal of Machine Learning Technologies. 2011. URL: https://www.researchgate.net/publication/276412348_Evaluation_From_precision_recall_and_F-measure_to_ROC_informedness_markedness_correlation (дата обращения: 05.03.2025)