

УДК 004.8

АНАЛИЗ АДАПТИВНОЙ МОДЕЛИ ИНТЕЛЛЕКТУАЛЬНОГО ЗВУКОВОГО МОНИТОРИНГА ПРОМЫШЛЕННОГО ОБОРУДОВАНИЯ

Верзун Н.А., Салиева А.А., аспирант

Научный руководитель: Колбанев М.О., д.т.н., профессор

СПбГЭТУ «ЛЭТИ»

г. Санкт-Петербург

Аннотация

В статье выполнен анализ современных методов интеллектуального звукового мониторинга промышленного оборудования. Показано, что традиционные и статические алгоритмы обработки акустической информации не обеспечивают устойчивости функционирования в условиях нестационарной промышленной среды, ресурсных ограничений и стохастического поступления событий. Проведена классификация существующих подходов (классические методы, глубокое обучение, ансамбли, генеративные модели), выявлены их системные ограничения. Обоснована необходимость разработки интегрированного алгоритмического комплекса на основе обучения с подкреплением, ансамблевых методов и генеративно-состязательных сетей.

Ключевые слова: системный анализ, звуковой мониторинг, промышленная диагностика, обучение с подкреплением, ансамбли моделей, GAN, адаптивные алгоритмы.

Введение

Современные производственные системы характеризуются высокой степенью автоматизации и цифровизации. В этих условиях надежность оборудования становится критическим фактором устойчивости технологических процессов. Согласно современным исследованиям в области Industrial AI и предиктивного обслуживания [1], интеллектуальный мониторинг состояния оборудования является ключевым элементом киберфизических производственных систем.

Звуковой мониторинг рассматривается как перспективное направление диагностики, поскольку акустические сигналы отражают широкий спектр физических процессов: вибрации, трение, кавитацию, износ подшипников и зубчатых передач. Вместе с тем промышленная акустическая среда существенно отличается от лабораторной: она характеризуется высоким уровнем шумов, множественностью источников сигналов и изменчивостью режимов работы [2].

Проведенный анализ литературы показал, что существующие решения в основном ориентированы на повышение точности классификации сигналов, однако недостаточно учитывают системные ограничения по времени реакции, вычислительным ресурсам и надежности. Это позволяет утверждать, что задача звукового мониторинга должна быть сформулирована как задача системного анализа и синтеза алгоритмов управления информационным процессом.

Цель настоящей статьи - на основе анализа современных исследований обосновать необходимость разработки адаптивных алгоритмов звукового мониторинга на основе обучения с подкреплением, ансамблевых методов и генеративно-сопоставительных сетей.

1. Анализ среды функционирования звукового мониторинга

Рассмотрим систему мониторинга как киберфизическую систему, включающую объект контроля, акустическую среду, сенсорный уровень, вычислительный модуль и контур принятия решений. На рис.1. представлена причинно-следственная диаграмма недостаточности традиционных методов




Рисунок 1- Причинно-следственная диаграмма недостаточности традиционных методов

Функционирование системы определяется следующими факторами (табл. 1).

Таблица 1 - Факторы промышленной акустической среды

Фактор	Проявление	Системное следствие
Нестационарность режимов	Изменение спектральных характеристик	Дрейф признаков
Высокий уровень шумов	Низкое SNR	Рост вероятности ошибок
Множественность источников	Перекрытие сигналов	Неопределенность диагностики
Дефицит аварийных данных	Редкие отказы	Переобучение моделей
Ограниченные ресурсы	Edge-вычисления	Ограничение сложности алгоритмов

Из приведенных факторов следует, что среда функционирования является динамической и частично наблюдаемой. Это приводит к росту вероятности ошибки распознавания P_{err} , что, в свою очередь, влияет на нагрузку системы:

$$\lambda_{eff} = \lambda(1 + P_{err}) \quad (1)$$

Где: λ — исходная интенсивность поступления акустических событий (событий/с); P_{err} — вероятность ошибки распознавания (суммарная вероятность ложной тревоги и пропуска события); λ_{eff} — эффективная интенсивность потока событий, требующих повторной обработки или дополнительной проверки[3].

Из выражения (1) следует, что рост вероятности ошибки приводит к увеличению нагрузки системы и, как следствие, к ухудшению вероятностно-временных характеристик функционирования.

Таким образом, ошибки распознавания имеют системные последствия: увеличивается объем повторной обработки, растет задержка реакции, снижается вероятность своевременного обнаружения дефекта.

Следовательно, проблема носит системный характер и требует комплексного алгоритмического решения.

2. Анализ существующих методов интеллектуального звукового мониторинга

Переходя от системного описания среды функционирования к анализу применяемого алгоритмического инструментария, необходимо рассмотреть современные методы обработки акустической информации, используемые в промышленной диагностике в 2020–2025 гг.

Классические методы обработки сигналов

Исторически задачи звукового мониторинга решались на основе спектральных критериев, пороговых правил и экспертно заданных признаков. Применялись[4-6]:

- анализ спектра и спектральной плотности мощности;
- кепстральные коэффициенты (MFCC);
- статистические показатели временного сигнала;
- пороговые правила принятия решений.

Несмотря на простоту реализации и интерпретируемость, данные методы предполагают относительную стационарность сигналов и фиксированные условия регистрации. В промышленной среде эти предпосылки нарушаются.

В условиях низкого отношения сигнал/шум и перекрытия источников диагностические признаки частично маскируются, что приводит к росту вероятности ошибки P_{err} . Согласно формуле (1), это увеличивает эффективную интенсивность обработки λ_{eff} , что системно ухудшает функционирование мониторинга.

Следовательно, классические методы обладают ограниченной устойчивостью к нестационарности и шумам.

Глубокое обучение

В широкое распространение получили методы глубокого обучения для диагностики по акустическим и виброакустическим сигналам [6]. Используются CNN, CRNN, трансформеры. Эти модели демонстрируют высокую точность в контролируемых условиях.

Однако анализ публикаций показывает следующие ограничения:

- деградация точности при изменении режима эксплуатации;
- чувствительность к шуму;
- необходимость большого объема размеченных данных;
- отсутствие механизмов адаптивного управления режимами анализа.

Таким образом, глубокое обучение эффективно на уровне извлечения признаков, но не решает задачу системной адаптации.

Ансамблевые методы

Ансамбли моделей применяются для повышения устойчивости диагностики [7]. Комбинирование различных классификаторов позволяет снизить дисперсию оценок и повысить обобщающую способность.

Тем не менее, в большинстве работ ансамбли используются статически, без адаптации весов в процессе эксплуатации. В условиях нестационарности среды это ограничивает эффективность ансамблевых решений.

Генеративно-сопоставительные сети (GAN)

GAN активно применяются для генерации синтетических данных отказов и расширения обучающей выборки [8]. Это особенно важно при редких аварийных режимах.

Однако существующие исследования в основном ограничиваются этапом предварительного обучения. Механизмы динамического обновления распределения данных в процессе эксплуатации разработаны недостаточно.

2.4 Обучение с подкреплением

В последние годы RL рассматривается как инструмент адаптивного управления в промышленной диагностике [9,10]. Он позволяет формировать политику действий в условиях частичной наблюдаемости.

Тем не менее, в области звукового мониторинга системная интеграция RL с методами извлечения признаков и генерации данных пока остается недостаточно исследованной.

3. Обобщение результатов анализа и постановка проблемы

Проведенный анализ показывает:

1. Глубокие модели обеспечивают извлечение устойчивых признаков, но не решают проблему адаптации.
2. Ансамбли повышают устойчивость, но требуют динамической настройки.
3. GAN компенсируют дефицит данных, но не интегрированы в контур эксплуатации.
4. RL обеспечивает адаптивность, однако редко применяется в составе комплексной архитектуры мониторинга.

Следовательно, существует научная проблема разработки интегрированной системы, объединяющей указанные подходы в рамках системного управления.

4. Постановка задачи дальнейшего исследования

На основании выполненного системного анализа формулируется задача разработки алгоритмического комплекса интеллектуального звукового мониторинга, включающего:

1. Блок глубокого обучения для формирования робастных признаков.
2. Ансамблевый механизм агрегации моделей для повышения устойчивости.
3. Генеративно-сопоставительный модуль для расширения выборки редких отказов.
4. RL-агент для адаптивного управления политикой обработки и принятия решений.

Задача формализуется как задача принятия решений в условиях частичной наблюдаемости (POMDP), где требуется минимизировать интегральный критерий, учитывающий вероятность ошибки, задержку реакции и вычислительные затраты.

Таким образом, дальнейшие исследования должны быть направлены на синтез адаптивных алгоритмов, обеспечивающих системную оптимизацию показателей мониторинга в реальных промышленных условиях.

Заключение

В статье проведен системный анализ современного состояния методов интеллектуального звукового мониторинга промышленного оборудования. Показано, что существующие подходы обладают ограниченной устойчивостью в условиях нестационарной акустической среды.

На основе анализа современных исследований обоснована необходимость разработки адаптивных алгоритмов на основе обучения с подкреплением, ансамблевых методов и генеративно-сопоставительных сетей.

Сформулирована постановка задачи дальнейшего синтеза интегрированной интеллектуальной системы мониторинга

Список литературы (2020–2025)

1. Lee J., Davari H., Singh J., Pandhare V. Industrial AI and predictive analytics for smart manufacturing systems // Manufacturing Letters. — 2020. — Vol. 18. — P. 21–25.
2. Zhang W., Li C., Peng G., Chen Y., Zhang Z. A deep learning-based approach for fault diagnosis: A review // IEEE Access. — 2021. — Vol. 9. — P. 16016–16027.
3. Jiang H., Li X., Zhang H. Robust acoustic fault diagnosis under noisy environments using deep learning // Sensors. — 2022. — Vol. 22, No. 4. — Article 1453.
4. Wen L., Gao L., Li X. A new deep transfer learning based on sparse auto-encoder for fault diagnosis // IEEE Transactions on Industrial Informatics. — 2020. — Vol. 16, No. 9. — P. 6198–6208.
5. Li X., Ding Q., Sun J. Remaining useful life estimation in prognostics using deep learning: A review // Reliability Engineering & System Safety. — 2020. — Vol. 172. — P. 1–15.

6. Liu Q., Chen X., Zhou J. Ensemble learning for machinery fault diagnosis: A review and comparative study // IEEE Transactions on Industrial Electronics. — 2022. — Vol. 69, No. 6. — P. 5970–5981.

7. Gao L., Zhang Y., Li X. GAN-based data augmentation for fault diagnosis of rotating machinery // IEEE Access. — 2023. — Vol. 11. — P. 35621–35634.

8. Chen B., Li Y., Zhang H. Reinforcement learning for adaptive fault diagnosis in industrial systems // IEEE Transactions on Industrial Informatics. — 2023. — Vol. 19, No. 8. — P. 8934–8945.

9. Wang H., Ma Y., Zhao D. Deep reinforcement learning for resource-constrained edge intelligence in industrial IoT // IEEE Internet of Things Journal. — 2024. — Vol. 11, No. 2. — P. 1784–1796. \ Silver D., Singh S., Precup D., Sutton R. Reward is enough // Artificial Intelligence. — 2021. — Vol. 299. — Article 103535.

10. Haarnoja T., Zhou A., Abbeel P., Levine S. Soft Actor-Critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor // IEEE Transactions on Neural Networks and Learning Systems. — 2022. — Vol. 33, No. 11. — P. 6196–6208.

11. Zhao R., Yan R., Chen Z., Mao K., Wang P., Gao R.X. Deep learning and its applications to machine health monitoring: A survey // Mechanical Systems and Signal Processing. — 2020. — Vol. 115. — P. 213–237.