УДК 620.111.3:004.85

АКУСТИЧЕСКАЯ ДИАГНОСТИКА ТЕХНОЛОГИЧЕСКОГО ОБОРУДОВАНИЯ ПРИ МАЛОМ ЧИСЛЕ РАЗМЕЧЕННЫХ ПРИМЕРОВ ОТКАЗОВ

Черняев Г. Ю., Хисамиев И. Л.

Казанский национальный исследовательский технический университет им. А. Н. Туполева – КАИ

г. Казань, Российская Федерация

Цифровизация производства смещает обслуживание оборудования от ремонтов по календарю к обслуживанию по фактическому состоянию [1], а состояние нужно чем-то измерять. Акустический канал выгодно отличается от вибрационного: регистрация пассивна и бесконтактна, не требует монтажа датчиков на корпус агрегата, доступа к его системе управления и остановки процесса. Микрофон рядом с оборудованием фиксирует изменения звуковой сигнатуры — рост гармоник частоты вращения, ударные импульсы, кавитационные шумы. Препятствием оказывается не физика, а данные.

Дефицит размеченных отказов. Методы обучения с учителем, показывающие высокое качество на акустических задачах, требуют порядка сотен размеченных примеров на класс. Для отказов промышленного оборудования такой выборки не существует по фундаментальной причине: отказы редки, записей аварийных режимов единицы, а специально доводить агрегат до разрушения ради обучающей выборки экономически бессмысленно. Поэтому в акустическом мониторинге доминируют методы обнаружения аномалий, обучаемые только на записях нормальной работы, — такова, в частности, постановка эталонного набора MIMII [2]. Однако детектор аномалий отвечает лишь на вопрос, отклонилось ли состояние от нормы, и не различает вид деградации, тогда как службе

эксплуатации нужно знать, что именно происходит с агрегатом: разбалансировка ротора, износ подшипника, утечка или кавитация.

Предлагаемый подход. Задача ставится как классификация при малом числе размеченных примеров. Обработка строится из двух частей. Предобученный на корпусе AudioSet свёрточный энкодер, например PANNs CNN14, переводит мел-спектрограмму записи в вектор признаков фиксированной размерности [3]; его веса заморожены, поэтому обучение на стороне пользователя не требует ни больших выборок, ни значительных вычислительных ресурсов. Поверх признакового пространства работает метрический классификатор на прототипах: класс описывается средним вектором своих немногочисленных примеров, а решение принимается по расстоянию до прототипов [4]. Такая схема позволяет ввести новый вид деградации, располагая 5–20 записями, без переобучения энкодера, тогда как классический дообучающий подход потребовал бы на порядок большей выборки.

Основание для переноса. Схема отрабатывается автором на задаче идентификации воздушных объектов по шуму винтомоторной группы. Перенос на промышленное оборудование оправдан тем, что меняется объект наблюдения, а не конвейер обработки: природа признаков та же — гармоники частоты вращения и ударные импульсы, — и та же причина дефицита данных. Регистрирующая часть тоже остаётся прежней: MEMS-микрофон с АЦП на микроконтроллере, передающий поток на вычислительный узел.

Направление дальнейшей работы. Предстоит получить зависимости качества идентификации от числа примеров на класс при значениях 1, 5, 10 и 20, сравнить метрическую схему с детектором аномалий и оценить устойчивость признакового пространства к смене экземпляра оборудования и акустической обстановки цеха. Проверка планируется на открытых наборах записей промышленных агрегатов.

Выводы. Узкое место акустической диагностики оборудования — не чувствительность измерительного тракта, а объём размеченных данных об отказах. Сочетание предобученного энкодера с метрической классификацией по прототипам переводит задачу в режим, где добавление нового вида деградации требует единиц примеров, что делает диагностику по звуку практически применимой в условиях реального производства.

Список использованной литературы

1. Кравченко Д.Д. Интеллектуальный мониторинг состояния оборудования компрессорных станций для предупреждения отказов и аварий / Д.Д. Кравченко, Е.Л. Чижевская, А.В. Медведев, Ю.Д. Земенков // Тюменский научный журнал. – 2025. – Т. 5, № 1. – С. 18–24.

2. Purohit H. MIMII Dataset: Sound Dataset for Malfunctioning Industrial Machine Investigation and Inspection / H. Purohit, R. Tanabe, K. Ichige [et al.] // Proceedings of the 4th Workshop on Detection and Classification of Acoustic Scenes and Events (DCASE). – 2019.

3. Kong Q. PANNs: Large-Scale Pretrained Audio Neural Networks for Audio Pattern Recognition / Q. Kong, Y. Cao, T. Iqbal [et al.] // IEEE/ACM Transactions on Audio, Speech, and Language Processing. – 2020. – Vol. 28. – P. 2880–2894.

4. Snell J. Prototypical Networks for Few-shot Learning / J. Snell, K. Swersky, R. Zemel // Advances in Neural Information Processing Systems. – 2017. – Vol. 30. – P. 4080–4090.