

**ПРОГРАММНЫЙ МОДУЛЬ РАСПОЗНАВАНИЯ ДЕФЕКТОВ ТЕХНИЧЕСКИХ
ОБЪЕКТОВ ПО НЕСТАЦИОНАРНЫМ СИГНАЛАМ МОНИТОРИНГА С
ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ**

Паршинцева А.О.¹

Научный руководитель – Русак А.В.¹

¹Университет ИТМО

parshintseva-s@yandex.com

Введение

Одной из актуальных проблем информационных систем мониторинга является распознавание дефектов технических объектов по потоковым измерениям, которые в реальных условиях являются нестационарными и содержат переходные процессы, шум, пропуски и дрейф режимов. Сложность решения рассматриваемой проблемы заключается в том, что даже при одинаковой природе измерений распределения данных и спектрально-временная структура сигналов могут существенно изменяться во времени, что снижает переносимость моделей и воспроизводимость качества. В исследованиях по разложению нестационарных рядов (эмпирическая модовая декомпозиция) показана эффективность адаптивных представлений, однако отмечается зависимость результата от структуры сигнала и помех [1]. В работах по синхросжатому вейвлет-преобразованию предложены более устойчивые временно-частотные оценки, но сохраняется необходимость корректного выбора параметров анализа [2]. Обзоры по глубинной классификации временных рядов фиксируют прогресс моделей, но указывают на проблемы обобщения при смене домена и на высокую потребность в разметке [3]. Следовательно, целью работы является разработка программного средства для распознавания дефектов по данным мониторинга на основе устойчивых представлений нестационарных сигналов, а также механизмов переноса и адаптации моделей.

Основная часть

Разработан прототип программного модуля распознавания дефектов технических объектов по данным мониторинга, реализующий модульный конвейер обработки нестационарных сигналов. Прототип включает прием и валидацию входных временных рядов, предобработку и контроль качества данных, сегментацию на скользящие окна, построение представлений сигналов, модуль классификации, а также протоколирование результатов экспериментов.

В прототипе реализована базовая ветвь анализа, опирающаяся на интерпретируемые признаки временной и частотной областей, дополненная адаптивными разложениями и временно-частотными представлениями. В качестве теоретической основы для адаптивного анализа нестационарных рядов использованы подходы эмпирической модовой декомпозиции [1]. В качестве направления построения более «сфокусированных» временно-частотных оценок рассмотрено синхросжатое вейвлет-преобразование как EMD-подобный инструмент [2].

Для распознавания дефектов применены модели машинного обучения, обучаемые на сформированном признаковом описании, при этом архитектура допускает подключение обучаемых представлений временных рядов в соответствии с современными подходами глубокого обучения для классификации временных рядов [3]. Для повышения переносимости при смене режимов и источников данных предусмотрены процедуры переноса и дообучения, соответствующие постановкам трансферного обучения [4]. Возможность доменной адаптации заложена на уровне экспериментального контура и может быть реализована методами обучения инвариантных признаков на основе градиентного разворота [5]. Сопоставимость вариантов представлений и алгоритмов

обеспечивается единым контуром экспериментов и принципами бенчмаркинга методов классификации временных рядов [6].

Выводы

Разработана методика распознавания дефектов оборудования по нестационарным сигналам и прототип программного модуля для ее применения в информационных системах мониторинга. Принятая комбинация интерпретируемых временно-частотных представлений и обучаемых признаков позволяет совместить объяснимость результата с переносимостью между режимами и доменами. Архитектура решения поддерживает расширение на другие прикладные области, включая цифровое здоровье, инфраструктурный мониторинг, энергетику, телематику, технологические процессы, телеком и кибербезопасность.

Литература

1. Huang N. E., Shen Z., Long S. R. и др. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis // *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences.* – 1998. – Т. 454, № 1971. – С. 903–995.
2. Daubechies I., Lu J., Wu H.-T. Synchrosqueezed wavelet transforms: An empirical mode decomposition-like tool // *Applied and Computational Harmonic Analysis.* – 2011. – Т. 30, № 2. – С. 243–261.
3. Fawaz H. I., Forestier G., Weber J. и др. *Deep learning for time series classification: a review* // *Data Mining and Knowledge Discovery.* – 2019. – Т. 33, № 4. – С. 917–963.
4. Pan S. J., Yang Q. *A survey on transfer learning* // *IEEE Transactions on Knowledge and Data Engineering.* – 2010. – Т. 22, № 10. – С. 1345–1359.
5. Ganin Y., Lempitsky V. *Unsupervised Domain Adaptation by Backpropagation* // *Proceedings of the thirty-second International Conference on Machine Learning (ICML).* – 2015. – Т. 37. – С. 1180–1189.
6. Bagnall A., Lines J., Bostrom A. и др. *The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances* // *Data Mining and Knowledge Discovery.* – 2017. – Т. 31. – С. 606–660.

Автор _____ Паршинцева А.О.

Научный руководитель _____ Русак А.В.