

УДК 339.54.012

ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ДИАГНОСТИКИ НЕИСПРАВНОСТЕЙ АВТОМОБИЛЬНОГО ДВИГАТЕЛЯ

Афанасьев Александр Диомидович,

доктор физико-математических наук профессор, Иркутский национальный
исследовательский технический университет, г. Иркутск

Соболинский Игорь Александрович,

магистрант, Институт информационных технологий и анализа данных, Иркутский
национальный исследовательский технический университет, г. Иркутск

Аннотация

В статье приведен анализ использования технологий искусственного интеллекта для диагностики неисправностей двигателей автомобилей. Обсуждаются методы подготовки аудиосигналов двигателя к анализу (выделение мел-частотных кепстральных коэффициентов – MFCC, построение спектрограмм), архитектуры сверточных нейронных сетей (CNN) для классификации акустических данных и методы аугментации аудиоданных. На основе обзора литературы доказано, что совокупность этих методов позволяет выявлять особые признаки неисправностей на ранних этапах с высокой точностью. Модели сверточных нейронных сетей, используя лог-мел-спектрограммы, демонстрируют показатели точности выше 98%, в то время как комплексные каскады могут обеспечить до 93-94% правильных классификаций типов поломок.

Выполненные результаты анализа демонстрируют перспективность использования диагностики звука работы двигателя с использованием искусственного интеллекта.

Ключевые слова: искусственный интеллект, диагностика двигателя, аудиосигналы, нейронные сети, машинное обучение

USING ARTIFICIAL INTELLIGENCE TO DIAGNOSE CAR ENGINE PROBLEMS

Afanasiev Alexander Diomidovich,

D. Sci. (Phys.-Math.), Professor, Irkutsk National Research Technical University, Irkutsk
e-mail: aad@ex.istu.edu

Sobolinskiy Igor Alexandrovich,

Master`s Student, Irkutsk National Research Technical University, Irkutsk
e-mail: sobolinskii@mail.ru

ABSTRACT

This article analyzes the use of artificial intelligence technologies for diagnosing automotive engine faults. It discusses methods for preparing engine audio signals for analysis (extracting log-mel cepstral coefficients (MFCCs) and constructing spectrograms), convolutional neural network (CNN) architectures for classifying acoustic data, and audio data augmentation methods. A literature review demonstrates that the combination of these methods enables the early detection of specific fault signs with high accuracy. Convolutional neural network models using log-mel spectrograms demonstrate accuracy rates exceeding 98%, while complex cascades can provide up to 93-94% correct classification of fault types.

These analysis results demonstrate the potential for using artificial intelligence to diagnose engine sound.

Keywords: artificial intelligence, engine diagnostics, audio signals, neural networks, machine learning

Введение

Современные автомобили являются сложными высокотехнологичными комплексами, в которых сочетаются элементы электронных, механических и программных устройств. Следовательно, диагностика и ремонт автомобилей становится все более ресурсоемкой. Основными проблемами для большинства автомобилистов и новичков в автомобильном деле являются определение причин автомобильных проблем, выбор наиболее эффективных способов их решения и поиск проверенных рекомендаций.

В то же время традиционные методы диагностики автомобильных двигателей, основанные на осмотре, измерениях или использовании особых диагностических приборов, нередко являются трудоемкими и требующими значительных временных и ресурсных затрат.

Так, например, в ряде исследований было отмечено, что для традиционного диагностического метода требуется высокая квалификация специалистов, а также значительные временные затраты на осмотр и тестирование, что делает этот метод менее эффективным в массовой практике обслуживания транспортных средств, особенно при высоких нагрузках [12].

Такие ограничения стимулируют исследователей к разработке автоматизированных методов диагностики, в частности основанных на анализе акустических и вибрационных параметров двигателя с применением методов машинного обучения [12, 15].

В то же время современные технологии искусственного интеллекта (ИИ) меняют представление о том, как должна выполняться диагностика автомобильных двигателей. Исследования продемонстрировали потенциал искусственного интеллекта в обнаружении неисправностей на ранних этапах, снижении вероятности ошибок человека, а также в существенном упрощении процессов технического обслуживания [2-5].

Цель исследования заключается в сокращении временных и трудовых затрат на первичную диагностику двигателя автомобиля с помощью методов искусственного интеллекта.

Методы предобработки и анализа аудиосигналов в интеллектуальной диагностике автомобильных двигателей

Диагностика двигателей по акустическим сигналам предлагает новые перспективы для выявления неисправностей без необходимости демонтажа двигателя. Обычно используемые методы требуют осмотра двигателя, проведения измерений или

использования сложного оборудования, что вызывает значительные временные и финансовые затраты, а также включает человеческий фактор. Вручную выполненные осмотры не всегда точны и могут быть замедлены. Вовремя выявленные неисправности могут быть пропущены даже опытными механиками, если те устали или не внимательны [1].

С другой стороны, системы, построенные на базе искусственного интеллекта, позволяют достичь высокого уровня точности в диагностике, ускорить процесс проверки, а также минимизировать расходы. Например, в ходе тестирования автомобилей Hyundai модуль, который анализирует звук работающего двигателя, показал правильный ответ в 87,6% случаев, тогда как люди справились со своей задачей в 8,6% [4]. Это доказывает возможности звуковой диагностики, поскольку благодаря применению алгоритмов машинного обучения и нейронных сетей почти полностью можно исключить ошибки человека.

Далее рассмотрим ключевые этапы построения такой системы: методы предобработки аудиосигналов, архитектуры нейронных сетей для анализа и подходы к повышению устойчивости моделей к шумовым помехам.

Современные методы предобработки аудиосигналов

Правильная предобработка аудиосигналов играет важнейшую роль при диагностике. В большинстве случаев для начала процесса используется извлечение спектральных или кепстральных признаков из звуковой волны двигателя. Одним из самых популярных методов для извлечения признаков является применение мел-частотных кепстральных коэффициентов (MFCC). MFCC представляют спектральную огибающую звука в виде набора коэффициентов при помощи модели восприятия звука человеческим ухом. В отличие от анализа «сырой» звуковой волны двигателя, MFCC обеспечивают информативное и относительно устойчивое по отношению к времени представление сигналов. В большинстве случаев используются 12 MFCC, которые обеспечивают оптимальное соотношение информативности и компактности признаков [6]. Кроме MFCC, для извлечения признаков также используются спектрограммы, представляющие звук в виде преобразования звуковой волны в пространство «время - частота».

Исследования подтверждают, что спектрограммы нередко оказываются информативнее, чем временной сигнал: на них проще выявить аномалии и характерные частотные признаки неисправностей. При формировании спектрограмм особенно важны параметры оконного преобразования. Один из современных подходов состоит в том, чтобы применять окно размером 2048 отсчетов с перекрытием 512. Такая конфигурация обеспечивает качественное разрешение как по времени, так и по частоте: окно 2048 позволяет получить точное разбиение по частоте, а шаг 512 сохраняет непрерывность анализа во времени [4].

Кроме MFCC и спектрограммы, для предобработки можно использовать и другие признаки, такие как вейвлет-преобразование или статистические признаки, отражающие форму сигнала. В частности, для нестационарных сигналов оно оказывается эффективным и способно дополнять MFCC новыми характеристиками.

Исследования показывают, что комбинированное использование временных и спектральных признаков повышает точность классификации. В частности, в ряде работ мел-спектрограммы продемонстрировали лучшие результаты по сравнению с MFCC, так как обеспечивают более детализированное представление спектральной структуры звука [3, 15, 16]. Ключевые характеристики методов предобработки представлены в таблице 1.

Таблица 1 - Ключевые характеристики различных методов предобработки сигналов [15 –16]

Метод	Описание	Применение
MFCC (13 коэффициентов)	Отражают частотные особенности сигнала в мел-шкале; компактны и относительно инвариантны по времени.	Часто выбирают 12–13 коэффициентов; хорошо описывают тембр звука.
Спектрограмма (STFT)	Двухнаправленное время-частота представление; выявляет изменения частотного состава сигнала со временем.	Окно 2048/512 (длина/перекрытие) – компромисс между временем и частотой.
Быстрое преобразование Фурье (FFT)	Проводит разложение сигнала по частотным компонентам; недостаточно информативно для нестационарного звука.	Не учитывает временную эволюцию, применимо для статических характеристик.
Вейвлет-преобразование	Разбивает сигнал на части по масштабу (частоте) и времени; хорошо выявляет локальные временные аномалии.	Эффективно при наличии резких переходов или коротких взрывных шумов.

Архитектуры нейронных сетей для анализа акустических данных

Одним из подходов для анализа акустических данных является применение сверточных нейронных сетей (CNN). Сверточные нейронные сети (CNN) уже зарекомендовали себя как одна из наиболее эффективных технологий для решения задач, связанных с аудиоанализом. Например, применение 1D CNN напрямую к временному сигналу позволило достичь точности обнаружения неисправностей двигателя на отметке 99% [5]. В этом эксперименте сеть автоматически выделяла характерные признаки «щелчков» и шумов в аудиопотоке, демонстрируя результативность, значительно превосходящую другие методы.

Таковыми же эффективными являются и 2D-CNNs, обученные на спектрограммах или изображениях MFCC. Увеличение качества может обеспечить и многоканальный подход: при таком подходе звук анализируется сразу по нескольким представлениям. Так, каскадная архитектура, объединяющая анализ «сырого» сигнала, спектрограммы, MFCC и вейвлет признаки, может достичь валидационной точности порядка 93–94% при определении типа топлива и конфигурации двигателя, а также 93,6% при детекции пропусков зажигания [5].

Эти результаты подтверждают, что сочетание разных признаков (частотно-временных и временных) с современными архитектурами нейросетей приводит к заметному росту качества классификации. Кроме того, помимо сверточных сетей, в подобных системах могут применяться рекуррентные модели (LSTM) для анализа временных зависимостей, а также гибридные архитектуры CNN-RNN.

Исходя из этого можно сделать вывод: использование современных методов глубокого обучения с грамотно подобранными признаками позволяет достигать очень высокой точности (87,6%) при распознавании состояния двигателя [3–7].

В частности, для практического применения необходимо, чтобы такая система была достаточно стабильна даже при наличии фонового шума и разнообразии форм записи. В этом случае часто применяется аугментация данных. Это предполагает использование искусственно модифицированных копий аудиозаписей. К классическим приемам относятся изменения громкости, тональности, скорости воспроизведения и фонового шума в записи [5]. Эти методы имитируют реальные вариации записи и значительно повышают способность нейросети к обобщению. Для аугментации данных исследователи предлагают следующие параметры [5]:

- ±0.5, ±2.5, ±5 полутона, ±0.25 октавы (≈3 полутона),
- SNR от -10 до +20 дБ (примерно 5–20 %)
- изменение скорости воспроизведения от 0.92× до 1.08,
- Основные приёмы аугментации представлены в таблице 2.

Таблица 2 - Основные приемы аугментации

Метод аугментации	Описание	Рекомендуемые параметры
Изменение громкости	Масштабирование амплитуды для моделирования разных уровней звука [7, 11].	-
Сдвиг высоты тона (Pitch Shift)	Поднятие или понижение высоты тона без изменения длительности [7, 10, 11].	±0.5, ±2.5, ±5 полутона, ±0.25 октавы (≈3 полутона)
Добавление фонового шума	Смешивание с шумом (гауссовский, бытовой), для устойчивости модели к шумам [7, 10, 11].	SNR от -10 до +20 дБ (примерно 5–20 %)
Временной сдвиг (Time Shift)	Сдвиг аудиозаписи во времени (вперед/назад) [8].	-
Изменение скорости (Time Stretch)	Изменение скорости воспроизведения (темпа) без и/или с изменением тона [8].	Коэффициенты около 0.92–1.08
SpecAugment	Маскирование областей во временной и частотной областях спектрограмм [12].	-

Практические наблюдения показывают, что обучение на этих аугментированных записях существенно улучшает точность диагностики на тестовых наборах по сравнению со обучением на «чистых» записях [9, 11]. Более того, в целях повышения устойчивости системы разрабатываются специализированные архитектуры нейронных сетей. В частности, используются остаточные блоки (ResNet) и модули шумоподавления, что позволяет сохранять эффективность системы даже в случае крайне низкого отношения сигнал/шум. Сочетание продвинутых методов аугментации и встроенных механизмов шумоподавления делает систему диагностики более надежной в условиях реальной эксплуатации автомобилей.

Заключение

Подводя итог, следует выделить, что использование технологий искусственного интеллекта для анализа звука работы двигателя показывает высокую эффективность в задачах раннего выявления неисправностей. Показано, что предобработка сигналов с применением мел-частотных кепстральных коэффициентов и спектрограмм обеспечивает информативное представление данных, а современные архитектуры сверточных

нейронных сетей позволяют достичь высокой точности классификации различных состояний двигателя. Включение методов аугментации повышает устойчивость моделей к помехам и вариативности записей, что критически важно для практического применения.

Рассмотренные подходы показывают перспективность использования интеллектуальных систем диагностики аудио для сокращения времени и стоимости обслуживания автомобилей. Полученные результаты могут быть полезны при разработке прикладных диагностических решений и служат основанием для дальнейших исследований, направленных на адаптацию методов к условиям реальной эксплуатации и расширение базы данных аудиозаписей.

Список литературы:

1. Диагностика автомобильных проблем с помощью ИИ. – URL: <https://www.elsevision.com/ru/news/can-ai-diagnose-car-problems/> (дата обращения: 03.07.2025). – Текст: электронный.
2. Роль ИИ в инспекции автомобилей. – URL: <https://automarketolog.ru/kak-ii-uluchshaet-osmotr-avtomobilej/> (дата обращения: 03.07.2025). – Текст: электронный.
3. Erdoğan, F. A. Detection of Fault from Acoustic Signals in Automobile Engines using Deep Learning Techniques / F. A. Erdoğan, A. Küçükmanisa, Z. N. Kilimci // Kocaeli Journal of Science and Engineering. – 2023. – Vol. 6, No. 2. – P. 148–154.
4. Акустический анализ двигателя с использованием ИИ. – URL: <https://vesolv.ru/keis5.html> (дата обращения: 03.07.2025). – Текст: электронный.
5. Terwilliger, A. M. The AI Mechanic: Acoustic Vehicle Characterization Neural Networks / A. M. Terwilliger, J. E. Siegel. – 2022. – 34 p.
6. Раловец, С. М. Применение методов цифровой обработки сигналов и машинного обучения для ранней диагностики отклонений в работе двигателя / С. М. Раловец, А. А. Раловец, Л. Л. Мискевич, В. В. Деменковец // Компьютерные системы и сети : материалы конференции. – Минск: БГУИР, 2023.
7. Audio Data Augmentation: Techniques and Methods. – URL: <https://blog.pangeanic.com/audio-data-augmentation-techniques-and-methods> (дата обращения: 09.09.2025). – Текст: электронный.
8. Ma, E. Data Augmentation for Audio / E. Ma. – URL: <https://medium.com/@makcedward/data-augmentation-for-audio-76912b01fdf6> (дата обращения: 09.09.2025). – Дата публикации: 01.06.2019. – Текст: электронный.
9. Романовская, Ю. М. Методы аугментации аудио сигнала / Ю. М. Романовская, Е. А. Ильюшин // International Journal of Open Information Technologies. – 2023. – Т. 11, № 3. – С. 12–17.
10. Song, X. Combined Data Augmentation on EANN to Identify Indoor Anomalous Sound Event / X. Song, J. Xiong, M. Wang, Q. Mei, X. Lin // Applied Sciences. – 2024. – Vol. 14, No. 4. – Art. 1327.
11. Eklund, V.-V. Data Augmentation Techniques for Robust Audio Classification / V.-V. Eklund. – Tampere: Tampere University, 2019. – 72 p.
12. Huh, M. A Comparison of Speech Data Augmentation Methods Using S3PRL Toolkit / M. Huh, R. Ray, C. Karnei. – 2023. – 10 p. – URL: <https://arxiv.org/abs/2303.00510> (дата обращения: 09.09.2025). – Текст: электронный.

13. Rawat, P. A Comprehensive Study Based on MFCC and Spectrogram for Audio Classification / P. Rawat, M. Bajaj, S. Vats, V. Sharma // Journal of Information and Optimization Sciences. – 2023. – Vol. 44, No. 6. – P. 1057–1074.
14. Hafiz, N. F. Comparison of Mel Frequency Cepstral Coefficient (MFCC) and Mel Spectrogram Techniques to Classify Industrial Machine Sound / N. F. Hafiz, S. Mashohor, M. A. Rahman // 2023 15th International Conference on Software, Knowledge, Information Management and Applications (SKIMA). – 2023. – December 8. – URL: <https://ieeexplore.ieee.org/document/10387339> (дата обращения: 09.09.2025). – Текст: электронный.
15. Ananya, I. J. A Comparative Study on Approaches to Acoustic Scene Classification Using CNNs / I. J. Ananya, S. Suad, S. H. Choudhury, M. A. Khan // Advances in Computational Intelligence. MICAI 2021. Lecture Notes in Computer Science. – 2021. – Vol. 13067. – P. 81–91.

References:

1. Can AI diagnose car problems? – URL: <https://www.elscopevision.com/ru/news/can-ai-diagnose-car-problems/> (Accessed: 03.07.2025). – Text: electronic.
2. The role of AI in vehicle inspection. – URL: <https://automarketolog.ru/kak-ii-uluchshaet-osmotr-avtomobilej/> (Accessed: 03.07.2025). – Text: electronic.
3. Erdogfan, F. A. Determination of automobile engine faults from acoustic signals using deep learning methods / F. A. Erdogfan, A. Kucukmanisa, Z. H. Kilimci // KOJOSE. – 2023. – Vol. 6, No. 2. – P. 148–154.
4. Acoustic engine analysis using AI. – URL: <https://vesolv.ru/keis5.htmlb> (Accessed: 03.07.2025). – Text: electronic.
5. Terwilliger, A. M. The AI Mechanic: Acoustic Vehicle Characterization Neural Networks / A. M. Terwilliger, J. E. Siegel. – 2022. – 34 p.
6. Ralovets, S. M. Application of signal processing methods in biomedical systems / S. M. Ralovets. – Minsk: BSUIR, 2023.
7. Audio Data Augmentation: Techniques and Methods. – URL: <https://blog.pangeanic.com/audio-data-augmentation-techniques-and-methods> (Accessed: 09.09.2025). – Text: electronic.
8. Ma, E. Data Augmentation for Audio / E. Ma. – URL: <https://medium.com/@makcedward/data-augmentation-for-audio-76912b01fdf6> (Accessed: 09.09.2025). – Text: electronic.
9. Romanovskaya, Yu. M. Methods of audio signal amplification / Yu. M. Romanovskaya, E. A. Ilyushin // International Journal of Open Information Technologies. – 2023. – Vol. 11, No. 3. – P. 12–17.
10. Song, X. Combined Data Augmentation on EANN to Identify Indoor Anomalous Sound Event / X. Song, J. Xiong, M. Wang, Q. Mei, X. Lin // Applied Sciences. – 2024. – Vol. 14, No. 4. – Art. 1327.
11. Eklund, V.-V. Data Augmentation Techniques for Robust Audio Classification / V.-V. Eklund. – Tampere: Tampere University, 2019. – 72 p.

12. Huh, M. A Comparison of Speech Data Augmentation Methods Using S3PRL Toolkit / M. Huh, R. Ray, C. Karnei. – 2023. – 10 p. – URL: <https://arxiv.org/abs/2303.00510> (access date: 09.09.2025). – Text: electronic.
13. Rawat, P. A Comprehensive Study Based on MFCC and Spectrogram for Audio Classification / P. Rawat, M. Bajaj, S. Vats, V. Sharma // Journal of Information and Optimization Sciences. – 2023. – Vol. 44, No. 6. – P. 1057-1074.
14. Hafiz, N. F. Comparison of Mel Frequency Cepstral Coefficient (MFCC) and Mel Spectrogram Techniques to Classify Industrial Machine Sound / N. F. Hafiz, S. Mashohor, M. A. Rahman // 2023 15th International Conference on Software, Knowledge, Information Management and Applications (SKIMA). – 2023. – December 8. – URL: <https://ieeexplore.ieee.org/document/10387339> (access date: 09.09.2025). – Text: electronic.
15. Ananya, I. J. A Comparative Study on Approaches to Acoustic Scene Classification Using CNNs / I. J. Ananya, S. Suad, S. H. Choudhury, M. A. Khan // Advances in Computational Intelligence. MICAI 2021. Lecture Notes in Computer Science. – 2021. – Vol. 13067. – P. 81-91.