

САМОДИАГНОСТИКА СОСТАВНЫХ АГРЕГАТОВ БЛОКА УПРАВЛЕНИЯ АВТОНОМНЫМ ТРАНСПОРТНЫМ СРЕДСТВОМ

SELF-DIAGNOSIS OF THE COMPONENTS OF THE CONTROL UNIT OF A HEAVY- DUTY VEHICLE

**A. Verkner
K. Gorlova
D. Akimov
E. Guryanova
A. Mayak**

Summary. The paper considers the issues of automatic classification of vibration states of cars based on the use of convolutional neural network processing of vibration measurement data presented in spectral form and processed by a modified t-distribution method, and the knowledge of experts with experience in interpreting spectrograms characterizing the vibration states of composite aggregates of heavy-duty vehicles.

The developed spectrogram analysis model allows monitoring the condition of heavy-duty vehicles of various models in automatic mode and timely notifying the driver of signs of pre-emergency situations, as well as the type of possible malfunctions.

The data samples used in training the neural network classifier during experimental studies were formed on the basis of available archive files containing complete aperture data from car vibration sensors and information about the malfunctions detected in them.

Keywords: big data, vibration diagnostics, heavy-duty vehicles, transmission, internal combustion engine, intelligent system, software, deep machine learning, neural network, recurrent network, fault classification, t-distribution.

Веркнер Алексей Сергеевич

аспирант, ассистент, МИРЭА — Российский
технологический университет
aleksverk@mail.ru

Горлова Ксения Олеговна

аспирант, ассистент, МИРЭА — Российский
технологический университет
ko.gorlova@yandex.ru

Акимов Дмитрий Александрович

К.т.н. доцент, МИРЭА — Российский
технологический университет
akim-dmitrij@yandex.ru

Гурьянова Екатерина Олеговна

Старший преподаватель, МИРЭА — Российский
технологический университет
guryanova-e.o@yandex.ru

Маяк Александр Александрович

Аспирант, МИРЭА — Российский
технологический университет
alexmaiak@yandex.ru

Аннотация. В работе рассматриваются вопросы автоматической классификации вибросостояний автономных транспортных средств (далее по тексту: АТС) на основе использования свёрточной нейросетевой (CNN) обработки данных виброизмерений, представленных в спектральном виде и обработанных модифицированным методом главных компонент, и знаний экспертов, имеющих опыт интерпретации спектрограмм, характеризующих вибросостояния составных узлов и агрегатов АТС. Разработанная модель анализа спектрограмм позволяет осуществлять мониторинг состояния АТС в автоматическом режиме и своевременно оповещать о появлении признаков предаварийных ситуаций, а также о виде возможных неисправностей.

Ключевые слова: вибродиагностика, автономное транспортное средство, интеллектуальная система диагностики, CNN (convolutional neural network — свёрточные нейронные сети), DNN (deep neural network — глубокие нейронные сети).

Введение

В настоящее время существует три основных направления для виброакустического анализа и диагностики автономных транспортных средств: NVH — анализ (Noise, vibration and harshness — шум, вибрация и жёсткость), исследования экспертов-инженеров по анализу спектрограмм транспортных средств и интеллектуальные системы диагностики вибросигналов. Под автономными транспортными средствами (далее по тексту: АТС) будет пониматься наземное колёсное транспортное средство с высоким уровнем автоматизации.

Нельзя не отметить ряд проблем виброакустического анализа современных АТС, во-первых, к ним относят субъективность ощущения жесткости, которую трудно измерить в отличие от шума и вибрации, восприятие жёсткости будет меняться от водителя к водителю (от пассажира к пассажиру) [1,2]. Вторая проблема заключается в трудности анализа и испытаний, поскольку транспортные средства становятся более сложными за счет новых материалов, гибридных силовых агрегатов и электроники, поэтому понимание взаимодействия компонентов и их влияния на шум, вибрацию и неровности становится требует дополнительных усилий. Третья проблема основана на экономической эффективности:

баланс между улучшением виброакустических характеристик и затратами на дополнительные материалы и системы автоматического управления становится менее достижимым [3,4].

Источники шума и вибраций в АТС разделяют на внутренние и внешние. К внутренним будет относиться шум силовых агрегатов и узлов: двигателя, трансмиссии, дифференциала и подвески. Источниками внешних виброакустических сигналов будут шумы шин, ветра и дорожного полотна. Так как эти аспекты хорошо регламентированы в нормативно-правовых документах, остаётся проблема шума и вибраций со стороны неисправных деталей или узлов АТС.

Обзор современных методов в интеллектуальных системах диагностики

В работе [5] описывается создание сложного диагностического инструмента, использующего передовые методы глубокого обучения для улучшения обнаружения неисправностей в промышленных условиях, используется автоматическое извлечение признаков, возможности работы в режиме реального времени и высокая точность. В статье предлагается применять гибридную модель DNN (deep neural network) и одномерной CNN (D-dCNN) для вибродиагностики, которая автоматически извлекает высокоуровневые признаки из вибрационных сигналов, позволяя эффективно обнаруживать и изолировать неисправности в промышленных приложениях, достигая значительной точности в 92 %.

В статье [6] представлена адаптивная свёрточная нейронная сеть с перекрытием (AOCNN) для диагностики неисправностей по необработанным вибросигналам с учетом дисперсии сдвига и второстепенных вопросов, которая может быть адаптирована для диагностики вибрации грузовых автомобилей путем использования аналогичных методов извлечения признаков.

В следующем исследовании [7] авторами приводится осуществление вибродиагностики грузового автомобиля с использованием нейронных сетей, применение модифицированной нейронной сети ARTMAP для контролируемого обучения, использование передовых методов отслеживания вибрационных трендов и сбор данных с помощью акселерометров для мониторинга состояния и идентификации неисправностей в режиме реального времени.

В статье [8] описывается методология, включающая извлечение признаков с помощью спектрального анализа, а затем двухслойную нейронную сеть с обратным распространением для повторного отбора признаков и обнаружения неисправностей, оптимизацию признаков вибрации для повышения точности диагностики механических систем, таких как грузовые автомобили.

Работа [9] посвящена шумовым данным автомобиля для диагностики неисправностей и оценки уровня шума с использованием моделей глубокого обучения, в частности, с помощью анализа спектрограмм и конволюционных слоев.

В результате анализа систем вибродиагностики все рассмотренные системы, кроме системы мониторинга и защиты оборудования VM 600, разработанной VibroMeter, могут быть усовершенствованы путём внедрения в их программное обеспечение нейросетевого классификатора данных для создания возможности ранней диагностики неисправностей АТС автономно, без участия квалифицированного эксперта.

Чтобы провести вибродиагностику АТС с помощью нейронных сетей, можно использовать различные модели глубокого обучения, которые анализируют сигналы вибрации для обнаружения аномалий и классификации неисправностей. Интеграция свёрточных нейронных сетей (CNN) и глубоких нейронных сетей (DNN) показала значительные перспективы в этой области, обеспечивая эффективное извлечение признаков и высокую точность прогнозирования.

Для получения реальных и репрезентативных данных о шуме в исследованиях часто используются различные типы датчиков для детектирования сигнала с различными частотами и свойствами. Например, микрофонные датчики используются для улавливания звука в воздухе, а акселерометры и датчики вибрации используются для обнаружения шума, связанного с вибрацией компонентов транспортного средства. Комбинация различных датчиков позволяет получить полный набор данных о шуме, что полезно для модели глубокого обучения. Очень важно выбрать подходящую частоту дискретизации данных, чтобы обеспечить получение подробных сведений о шумовом сигнале.

Описание испытательного стенда

Сбор данных в виде вибрационных сигналов осуществляется с помощью испытательного стенда. Управление двигателем осуществляется инвертором класса LS600 с возможностью задания скорости вращения (60–3000 об/мин), времени разгона и останова. К ротору через упругую пластинчатую муфту крепится вал, установленный на опорах с подшипниками скольжения и качения. На валу располагаются съемные маховики с отверстиями для установки балансировочных грузов. Между маховиками находится опора со специальным механизмом, которым регулируется изгиб вала. Заканчивается вал диском фазовой отметки [7], используемым для определения частоты вращения и фазового сдвига между виброколебаниями на оборотной частоте и тахометрическим сигналом. Электродвигатель и все опоры установлены на инерционном основании.

Измерительная часть стенда представлена набором первичных средств измерения, комплектом модулей предусиления и управления, а также рядом виртуальных измерительных приборов. Для вибрационного контроля в качестве первичных средств измерения используются вибропреобразователи AP2037 со встроенной электроникой.

Модули предусиления и управления скомпонованы в блок управления, имеющий двенадцать входов для подключения вибропреобразователей AP2037 и четыре входа для подсоединения вихретоковых пробников AE050.00.07. Сформированные блоком управления электрические сигналы проходят цифровую обработку 16-канальным модулем АЦП «ZET 210».

Модуль ZET 210 функционирует в режиме непрерывного ввода/вывода аналоговых и цифровых сигналов в память персонального компьютера с возможностью цифровой обработки сигналов. Соотношение сигнал/шум составляет 86 дБ. Эффективная разрядность — 15 бит. Модуль АЦП предназначен для оцифровки сигналов постоянного уровня и переменного напряжения.

Процедура диагностирования по спектру огибающей складывается обычно из следующих операций:

Определяются частоты резонанса диагностируемых узлов (например, резонансная частота зубчатого колеса);

Определяются характерные частоты возмущений (например, зубцовая частота);

В процессе работы механизма определяют спектр огибающей. При этом полосовой фильтр (обычно 1/3 октавный) настраивают на частоту резонанса диагностируемого узла (зубчатого колеса);

В спектре огибающей следят за частотными составляющими, характерными для данного вида дефекта (зубцовая частота). Повышение коэффициента модуляции характерной гармоникой говорит о развитии дефекта.

Разработка программных средств машинного обучения интеллектуальной самодиагностики

Программные средства интеллектуальной системы диагностики базируются на распознавании аномалий образов спектрограмм с помощью разновидности свёрточной нейронной сети с возможностью обучения на сокращённом количестве данных — обобщенно-регрессионная нейронная сеть (GRNN — General Regression Neural Network). Данная нейросеть основана на теории непараметрической статистики и использует ядровые методы для аппроксимации функции. GRNN обладает способностью хорошо работать с небольшими объемами данных, устойчивостью к шуму и быстрым обучением.

При предварительных исследованиях структур нейронных сетей был создан алгоритм реконфигурации нейронной сети GRNN.

Для первого ядра свёртки для извлечения характеристик в конкретном случае был использован тип «Лапласиан» с акцентом на обнаружение основных гармоник.




Рис. 1. Блок измерений вибраций стенда генератора неисправности АТС




Рис. 2. Признаки неисправностей узлов конструкции АТС на шкале спектра виброизмерений

Сначала вводится конволюционный слой, и входные данные свертываются фильтрами для получения соответствующих характеристик. Конволюционная операция одиночного фильтра представлена в формуле (1):

$$y_n^l = f_l \left(\sum_{m \in V_n^l} y_n^{l-1} \otimes w_{m,n}^l + b_n^l \right), \quad (1)$$

где под оператором $\otimes$ понимается математическая операция свертки на матрице. В данном случае мощность блока признаков y_m^{l-1} равен $H^{l-1} \times W^{l-1}$, а мощность свертки $w_{m,n}^l$ равняется $r^l \times c^l$, тогда вводная матрица — y_m^l .

В слоях объединения GRNN важные признаки резервируются, а количество признаков уменьшается с помощью операции максимального объединения [15]. Работа одного фильтра может быть представлена как:

$$z_n^{l-1} = y_n^{l-1}(2i-1, 2j-1) + y_n^{l-1}(2i-1, 2j) + y_n^{l-1}(2i, 2j-1) + y_n^{l-1}(2i, 2j). \quad (2)$$

Ядро признакового поля n слоя объединения / вычисляется, как:

$$y_n^l = \min(f_l(z_n^{l-1} \times w_{m,n}^l + b_n^l)). \quad (3)$$

Карты признаков после извлечения признаков сплюсываются в одномерный массив и вводятся в полностью связанные слои. Работа одного нейрона в полностью связанных слоях представлена как:

$$R^l = \frac{R^{l-1}}{2}, M^l = \frac{M^{l-1}}{2}, \quad (4)$$

где R — входные нейроны, M — модифицированные весовые коэффициенты.

Алгоритм работы ИИ с применением нейросетевой структуры GRNN, выглядит следующим образом (рис. 3).

Одномерная GRNN с объединением датчиков в параллельную структуру, применяется для прогнозирования трендов неисправностей. Характеристики вибрационных сигналов в направлениях X, Y, Z извлекаются отдельно в виде 3D-спектрограмм. Для того чтобы получить структуру GRNN с лучшей производительностью, применяется оптимизация комбинации гиперпараметров [17-20]. Диапазон оптимизированных гиперпараметров и структура GRNN выбираются.




Рис. 3. Алгоритм работы программного обеспечения интеллектуальной системы диагностики

Выделение признаков для трех осевых сигналов одинаково. Производительность модели предполагается как функция гиперпараметров, которая представлена в виде

$$MAPE = fMAPE(FC, FP, NC1, NC2, NF1, NF2). \quad (5)$$

После проведения экспериментов функция между гиперпараметрами и средним MAPE тестирования моделируется с помощью MR и NN для сравнения. Производительность моделей, результаты оптимизации и верификации сравниваются следующим образом. Перед моделированием данные нормализуются.

Сначала моделирование с помощью пошагового MR имеет вид:

$$\begin{aligned} MAPE = & 35.818395 - 1.217292FC - 0.428033FP + \\ & + 0.758975NC1 + 0.991905NC2 + 0.140401NF1 - \\ & - 0.224964NF2 + 0.226124FCNF2 + 0.082959FCNC2 - \\ & - 0.046696FPNC2 + 0.01539FPNF2 - 0.044823NC1NC2 - \\ & - 0.000967NC1NF2 - 0.010024NC2NF1 - 0.00065NF1 \end{aligned} \quad (6)$$

Целью оптимизации является минимизация пригодности. Сочетание гиперпараметров, оптимизированное с помощью алгоритма полного факторного поиска, следующее: FC=25, FP=20, NC1=20, NC2=20, NF1=100, NF2=10.

Прогнозирование основывается на разработанной методике применения GRNN к временному ряду 3D-спектрограмм и анализу динамики смещения центроидов кластеров полносвязного слоя на временном ряду с интерполяцией вероятностей отказа для каждого 3D-образа спектрограмм. Центроиды кластеров $R_{cluster}$, полученные методом t-SNE, применительно к полносвязному слою GRNN, могут сходиться или расходиться друг относительно друга показывая динамику изменения остаточного ресурса во времени. Поэтапная обработка спектрограмм с помощью искусственного интеллекта, представленного глубинными нейронными сетями, показана ниже.

После проведения каждого этапа обучения проверялось качество обучения, достигнутое на данном этапе обучения, путем предъявления на входы ЭПК наборов входных данных, которые не участвовали в обучении. После чего рассчитывалась вероятность (доля) правильного и ложного распознавания (классификации) входных наборов данных и составлялась таблица максимальной вероятности неправильной классификации в зависимости от номера этапа обучения. Обучение считается успешным, если достоверность классификации неисправностей составляет не менее 0,95.

Роторная установка, у которой вибрация при скорости вращения 2х превышает 150 % от 1х, указывает на серьезную несоосность. Роторная установка должна как можно скорее отправиться на ремонт. Как упоминалось ранее в этом разделе, показания фаз являются еще одним фактором, который помогает определить точную проблему.

Фазовые измерения являются очень полезным инструментом для диагностики несоосности. Если возмож-




Рис. 4. Результаты работы интеллектуальной системы диагностики

но, измерьте сдвиг фаз между осевыми показаниями на противоположных концах ротора.

Чтобы оценить точность прогноза, мы рассчитываем коэффициент определения R^2 и среднюю абсолютную ошибку (MAE)[16,20]. Средний модуль отклонения (MAE — Mean Absolute Error или MAD — Mean Absolute Deviation) находится по формуле (7):

$$MAE = \frac{1}{m} \sum_{i=1}^m |a_i - y_i|, \quad (7)$$

a_i — прогнозируемый результат, y_i — фактический результат, m — размер выборки, R^2 — доля дисперсии зависимой переменной.

Определялось значение достоверности обнаружения прогнозируемой неисправности и показатели точности прогноза (таблица 1).

Исходя из анализа реакции оператора, можно сделать вывод об эффективности применения модуля прогнозирования категории неисправности.

Таблица 1.

Результаты нейросетевой классификации и зафиксированное распределение ошибки прогноза

№	Сигнал вида неисправностей	Достоверность определения	R^2	MAE
11	«Неудовлетворительное состояние подшипников ступиц колес»	0,95	0,86	750
22	«Износились или повреждены шарниры рулевого привода или нижний шарнир подвески»	0,95	0,81	640
33	«Раскрутились гайки или болты крепления колес»	0,98	0,94	620
44	«Изношены задние амортизаторы»	0,96	0,86	610
55	«Не отбалансированы передние колеса»	0,94	0,88	670
66	«Повреждение или деформация колес»	0,97	0,71	830
78	«Дефект подшипников»	0,99	0,9	680

Для этих входных данных рассчитывалась достоверность классификации неисправностей.

Достоверность классификации неисправностей по параметрам абсолютной вибрации опор подшипников вала БГА составила не менее 0,95.

Заключение

Таким образом, предлагается подход к анализу неисправностей большегрузных автомобилей, основанный на спектральных характеристиках. Для анализа

использовался аппарат модифицированного вейвлет-преобразования с применением нейронной сети типа рекуррентный автоэнкодер. В результате нейронная сеть научилась выявлять кластеры с критическими состояниями вибрации на временном участке более 24 ч. При появлении новых данных модуль прогнозирования установит кластер данных с дисперсией не более 0,2 и определит тип прогнозируемой неисправности.

Данный подход и методы имеют свои ограничения, исследования которых могут являться предметом дальнейшего поиска и экспериментов.

ЛИТЕРАТУРА

1. Асанов А.З. Моделирование динамики подвески большегрузного автомобиля в процессе преодоления препятствий / А.З. Асанов, А.С. Веркнер // Автоматизация и измерения в машино — приборостроении. — Севастополь: Издательство «Севастопольский государственный университет», 2023. — С. 11–22.
2. G.C. Stone, E.A. Boulter, I. Culbert, et al. Electrical Insulation for Rotating Machines, 2nd ed. Hoboken NJ: Wiley, 2014. — 672 с.
3. Шабает В.М., Казанцев А.С., Леонтьев М.К., Гаранин И.В., Карасев В.А. Вибродиагностика повреждений подшипников качения при монтаже и сборке тяжелых роторных узлов. // Контроль. Диагностика. ISSN: 0201-7032 М.: Издательский дом «Спектр», 2007. — №11. — С.18–27.
4. Dong Yul Oh and Il Dong Yun. Residual Error Based Anomaly Detection Using Auto-Encoder in SMD Machine Sound / Sensors. — 2018. — Vol. 18, — 1308 p.
5. Crina, Narcisa, Deac., Gicu, Calin, Deac., Radu, Constantin, Parpala., Cicerone, Laurentiu, Popa., Costel, Emil, Cotet. (2021). Vibration Anomaly Detection using Deep Neural Network and Convolutional Neural Network. International Journal of Modeling and Optimization, 19-28. doi: 10.7763/IJMO.2021.V11.772
6. Ugochukwu, Ejike, Akpudo., Jang-Wook, Hur. (2021). D-dCNN: A Novel Hybrid Deep Learning-Based Tool for Vibration-Based Diagnostics. Energies, 14(17):5286-. doi: 10.3390/EN14175286
7. Weiwei, Qian., Shunming, Li., Jinrui, Wang., Zenghui, An., Xingxing, Jiang. (2018). An intelligent fault diagnosis framework for raw vibration signals: adaptive overlapping convolutional neural network. Measurement Science and Technology, 29(9):095009-. doi: 10.1088/1361-6501/AAD101
8. Keming, Wang. (2006). Neural Network Approach to Vibration Feature Selection and Multiple Fault Detection for Mechanical Systems. 3:431–434. doi: 10.1109/ICICIC.2006.475
9. Kyoung, Jin, Noh., Dongchul, Lee., Jaemin, Jin., In-Soo, Jung., Joon-Hyuk, Chang. (2023). Development of Deep Learning-based Vehicle Diagnosis Technology Using Noise Data. Transactions of The Korean Society for Noise and Vibration Engineering, 33(3):306–312. doi: 10.5050/ksnve.2023.33.3.306
10. Веркнер А.С. Исследование принципов компенсации возмущения, действующего на динамику мобильного робота / А.С. Веркнер, К.О. Горлова, Е.О. Гурьянова // Актуальные проблемы прикладной математики, информатики и механики: сборник трудов Международной научной конференции. — Воронеж: Научно-исследовательские публикации, 2023. — С. 1500–1508.
11. Веркнер А.С. Разработка алгоритмов управления мобильным роботом с компенсацией возмущения / А.С. Веркнер, К.О. Горлова, Е.О. Гурьянова // Вестник воронежского государственного технического университета. — Воронеж: Издательство ФГБОУ ВО «Воронежский государственный технический университет», 2023. — С.16–24. DOI 10.36622/VSTU.2023.19.4.002.
12. Sarrazin M. Electro-vibro-acoustic analysis of electric powertrain systems / M. Sarrazin, K. Janssens, C. Wilfried, H. Van der Auweraer // FISITA WORLD AUTOMOTIVE CONGRESS. — 2014. — 9 p.
13. Охтилев М.Ю. Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов. / М.Ю. Охтилев, Б.В. Соколов, Р. М. Юсупов. — М.: Наука, 2006. — 410 с.
14. Lee J.Y., Derroncourt F. Sequential Short-Text Classification with Recurrent and Convolutional Neural Networks // Proceedings of NAACL-HLT. 2016. — pp. 515–520.
15. Назолин А.Л., Поляков В.И. Виброударные режимы движения в дефектном узле подвески сердечника статора мощного генератора. — Сборник трудов XV симпозиума «Динамика виброударных (сильно нелинейных) систем». Москва — Зеленоград: РАН — ИНМАШ им. А.А.Благонравова, 2006. — С.200–205/
16. Морозова Т.Ю., Бекаревич А.А., Будадин О.Н. Новый подход к идентификации дефектов материалов изделий. — Контроль. Диагностика. — № 8 (194), 2014, — С.42–48.
17. Акимов Д., Круг П., Остроух А., Ивченко В., Морозова Т., Садыков И. Имитационная модель автономного движения автоприцепа в условиях экстремальной и нестационарной среды. Международный журнал прикладных инженерных исследований, ISSN 0973-4562, Том 11, 2016. — С. 6435–6440.
18. Акимов Д.А. Применение компьютерного зрения в работе операторов управления на промышленных объектах.// Промышленные АСУ и контроллеры. Научтехлитиздат, 2011, №5, — С. 1–6.
19. Кулагин В., Иванов А. И., Кузнецов Ю. М., Чулкова Г. М. Многомерное взаимное упорядочение паттернов с использованием набора предварительно обученных искусственных нейронных сетей // Физический журнал: Серия конференций. 2017. Том 803. № 1, — С. 1–6.
20. Кулагин В., Акимов Д., Павельев С., Потапов Д. Автоматизированная идентификация критических неисправностей авиационных двигателей на основе модифицированного вейвлет-преобразования и кластеризации глубоких нейронных сетей IOP 1. Серия конференций: Материаловедение и инженерия. Том 714, выпуск 1, 3 января 2020 г., 714. 012014. Издательство Института физики DOI 10.1088/1757-899X/714/1/012014