

МАШИНОСТРОЕНИЕ

MACHINE BUILDING



УДК 621.86

Оригинальное эмпирическое исследование

<https://doi.org/10.23947/2541-9129-2026-10-2-166-176>

Интеллектуальная система поддержки принятия решений для комплексной диагностики взаимосвязанных систем автомобиля



EDN: OCLIOI

Р.В. Хван

Донской государственный технический университет, г. Ростов-на Дону

khvanroman@yandex.ru

Аннотация

Введение. Применение искусственных нейронных сетей (ИНС) для диагностики технического состояния машин активно исследуется, однако авторы публикаций в основном фокусируются на оценке отдельных агрегатов, например двигателя, без комплексного анализа взаимосвязанных систем автомобиля. Необходимо закрыть этот пробел в области создания интеллектуальных систем, способных одновременно учитывать состояние ходовой, тормозной и рулевой части. Цель исследования — разработка интеллектуальной системы поддержки принятия решений (ИСППР) для комплексной оценки технического состояния автомобиля на основе ИНС, обобщающей опыт экспертов и данные о повреждениях различных узлов.

Материалы и методы. Для дефектации деталей и узлов автомобилей использовались браковочные показатели, определенные по нормативным документам, а также руководства по эксплуатации, обслуживанию и ремонту. При нейросетевом моделировании для обучения ИНС использовался массив из 100 выборок, сформированных на основе:

- статистических данных,
- экспертных опросов специалистов Центра обслуживания и ремонта машин Донского государственного технического университета,
- анализа больших данных из интернет-источников.

Учитывались браковочные показатели 13 основных систем автомобиля, эксплуатационные факторы и психоэмоциональное состояние водителя. Обучающий массив включал параметры повреждения деталей рамы, мостов, подвески, колес, тормозной и рулевой систем. Для сравнения эффективности были построены и обучены многослойные перцептроны (MLP¹) с разным количеством нейронов в скрытых слоях, функциями активации и алгоритмом обучения BFGS² (три архитектуры).

Результаты исследования. Наилучшие результаты показала нейросеть MLP 8-24-3 (8 входных, 24 скрытых, 3 выходных нейрона). Ее производительность на обучающей выборке составила 93,75 %, на тестовой — 90 %. Точность классификации по категориям технического состояния достигла: 100 % для категории «эксплуатация разрешена», 94,74 % для «эксплуатация разрешена с ограничениями» и 82,35 % для «эксплуатация запрещена». Анализ чувствительности выявил, что наибольшее влияние на классификацию оказывают параметры рамы (X1) и мостов (X2).

Обсуждение. Разработанная ИНС продемонстрировала высокую эффективность в комплексной оценке технического состояния автомобиля. Показатели оказались существенно лучше, чем при диагностике отдельных агрегатов. Установлено, что весовые коэффициенты нейросети могут служить количественной мерой взаимосвязи и взаимного влияния деталей различных систем на общую безопасность. Полученные результаты подтверждают практическую применимость подхода для создания гибких ИСППР в сфере технического обслуживания и диагностики.

Заключение. Исследование вносит вклад в развитие методов интеллектуального анализа данных для транспортных систем. Предлагается новый подход к интеграции разнородных параметров и экспертного опыта в единую нейросетевую модель, что является важным шагом к повышению надежности и безопасности

¹ Multilayer perceptron (англ.).

² От англ. Broyden — Fletcher — Goldfarb — Shanno algorithm. Алгоритм Бройдена — Флетчера — Гольдфарба — Шанно.

© Хван Р.В., 2026

эксплуатации автомобильной техники. Интеллектуальная система, основанная на опыте экспертов и статистических данных, — перспективный инструмент для автоматизации процессов оценки и принятия решений. Дальнейшее развитие, повышение точности и эффективности системы может основываться на расширении базы данных и улучшении алгоритмов обучения.

Ключевые слова: диагностика технического состояния ходовой части, параметры повреждения деталей машин, оценка технического состояния с MLP 8-24-3, доверительные уровни определения технического состояния.

Благодарности. Автор выражает искреннюю благодарность коллективу Центра обслуживания и ремонта автомобильной техники Донского государственного технического университета за возможность использовать данные диагностики автомобильной техники, а также за доступ к статистической базе данных типовых повреждений.

Для цитирования. Хван Р.В. Интеллектуальная система поддержки принятия решений для комплексной диагностики взаимосвязанных систем автомобиля. *Безопасность техногенных и природных систем*. 2026;10(2):166–176. <https://doi.org/10.23947/2541-9129-2026-10-2-166-176>

Original Empirical Research

Intelligent Decision Support System for Comprehensive Diagnostics of Interconnected Vehicle Systems

Roman V. Khvan  

Don State Technical University, Rostov-on-Don, Russian Federation

 khvanroman@yandex.ru

Abstract

Introduction. The use of artificial neural networks (ANNs) to diagnose the technical condition of automotive equipment is an active area of research. However, existing work mainly focuses on evaluating individual units, such as the engine, without a comprehensive analysis of the interconnected systems of a car. This creates a gap in the field of the development of intelligent systems that can take into account the state of the chassis, braking, and steering systems at the same time. The aim of this study is to develop an intelligent decision-making support system (IDMSS) based on ANNs that can comprehensively assess the technical condition of a vehicle by combining expert knowledge and data on damage to different components.

Materials and Methods. Defective indicators, determined on the basis of regulatory documents, and manuals on operation, maintenance and repair, were used to defect car parts and assemblies. The research was based on the methodology of neural network modeling. To train the ANN, an array of 100 samples was used, formed on the basis of:

- statistical data,
- expert surveys of specialists from the Automotive Equipment Maintenance and Repair Center at Don State Technical University,
- analysis of big data from online sources.

Defective parameters of 13 main vehicle systems, operational factors and even the psycho-emotional state of the driver were considered. The training array included damage parameters for frame parts, axles, suspension, wheels, brake, and steering systems. To compare the effectiveness, three multilayer perceptrons (MLPs) architectures with different numbers of neurons in hidden layers, activation functions, and the BFGS learning algorithm were created and trained.

Results. The best results were shown by the MLP 8-24-3 neural network (8 input, 24 hidden, 3 output neurons). Its performance on the training sample was 93.75%, on the test sample — 90%. The accuracy of classification by category of technical condition reached 100% for the category “operation permitted”, 94.74% for “operation permitted with restrictions”, and 82.35% for “operation prohibited”. Sensitivity analysis revealed that the parameters of the frame (X1) and axles (X2) had the greatest influence on the classification.

Discussion. The developed ANN has demonstrated high efficiency in a comprehensive assessment of the vehicle's technical condition, going beyond the diagnosis of individual units. It has been established that the weighting coefficients of the neural network can serve as a quantitative measure of the relationship and mutual influence of the details of various systems on the overall safety. The results obtained confirm the practical applicability of the approach for creating flexible IDMSSs in the field of maintenance and diagnostics.

Conclusion. The research contributes to the development of data mining methods for transport systems, offering a new approach to integrating heterogeneous parameters and expertise into a single neural network model. It is an important step towards improving the reliability and safety of automotive equipment. An intelligent system based on expert experience and statistical data is a promising tool for automating assessment and decision-making processes. Further development of the system may include expanding the database and improving learning algorithms, which will increase its accuracy and efficiency.

Keywords: technical condition diagnostics of the chassis, parameters of damage to machine parts, technical condition assessment using MLP 8-24-3, confidence levels for determining the technical condition

Acknowledgements. The author would like to express his sincere gratitude to the staff of the Automotive Equipment Maintenance and Repair Center at Don State Technical University for the opportunity to use the diagnostic data on automotive equipment, as well as for access to the statistical database of typical damages.

For Citation. Khvan RV. Intelligent Decision Support System for Comprehensive Diagnostics of Interconnected Vehicle Systems. *Safety of Technogenic and Natural Systems*. 2026;10(2):166–176. <https://doi.org/10.23947/2541-9129-2026-10-2-166-176>

Введение. Для современных исследований в области диагностики автомобильной техники активно используются методы искусственного интеллекта, в частности искусственные нейронные сети (ИНС). Однако существующие разработки, как правило, ограничиваются анализом отдельных узлов, преимущественно двигателя внутреннего сгорания. Например, в работе [1] ИНС применяется для определения неисправностей двигателя без детализации архитектуры сети. В следующих исследованиях нейросетевые методы используются для диагностики по отдельным параметрам (отключение цилиндров [2], химический состав масла [3], температура цилиндров [4]), что не позволяет комплексно оценить техническое состояние двигателя. Существенный пробел — отсутствие подходов, способных интегрировать данные о состоянии взаимосвязанных систем автомобиля, например ходовой, тормозной и рулевой. Узконаправленный подход не учитывает их взаимное влияние на общую безопасность и работоспособность транспортного средства.

Таким образом, в научном знании сохраняется дефицит решений, обеспечивающих комплексную оценку технического состояния автомобиля на основе интеграции разнородных данных о повреждениях множества узлов и систем. Актуальность заполнения данного пробела подтверждается и требованиями нормативных документов, таких как ГОСТ Р 58197-2018, который предписывает проведение комплексной экспертизы с привлечением экспертного метода.

Целью данного исследования является разработка интеллектуальной системы поддержки принятия решений (ИСППР) для комплексной оценки технического состояния автомобиля на основе искусственной нейронной сети, обобщающей экспертный опыт и статистические данные о повреждениях.

Для достижения цели ставились перечисленные ниже задачи.

1. Сформировать массив обучающих данных на основе браковочных показателей, эксплуатационных факторов и экспертных оценок состояния основных систем автомобиля.
2. Для классификации технического состояния разработать и обучить нейронные сети типа многослойный перцептрон (MLP) с разными архитектурами.
3. Провести сравнительный анализ эффективности обученных сетей и выбрать оптимальную архитектуру.
4. Оценить чувствительность выбранной модели к изменению входных параметров и проанализировать результаты.

Материалы и методы. Исследование основывалось на методологии нейросетевого моделирования. Основные этапы работы включали сбор данных, проектирование архитектур нейронной сети, обучение и валидацию моделей. Для формирования массива обучающих данных использовался опыт специалистов Центра обслуживания и ремонта автомобильной техники Донского государственного технического университета (ДГТУ), а также результаты анализа статистических данных эксплуатации.

Для дефектации деталей и узлов автомобилей использовались браковочные показатели. Их состав определяли с учетом рекомендаций нормативных документов, а также руководств по эксплуатации, обслуживанию и ремонту автомобильной техники. Возможности искусственных нейронных сетей позволили комплексно учесть разнородные исходные данные при оценке технического состояния автомобильной техники. Кроме браковочных показателей учитывались эксплуатационные факторы:

- срок эксплуатации;
- ресурс каждого исследуемого узла, системы или детали;
- количество циклов нагружения.

При этом для оценки технического состояния той или иной системы автомобиля достаточно имеющихся исходных данных, то есть их наличие или отсутствие не ограничивает работоспособность системы поддержки принятия решений, а лишь влияет на доверительные уровни оценки [5]. Это свойство искусственных нейронных систем роднит их с биологическими нейронными сетями. Оценивая ситуацию, риски или техническое состояние машины, человек использует именно те данные, которые у него есть, именно тот опыт, которым он обладает. Отсутствие тех или иных данных не ведет к отказу мыслительной системы, а лишь понижает доверительный уровень оценки [6].

На рис. 1 представлена интеллектуальная система поддержки принятия решений при оценке технического состояния автомобиля. Вычислительное ядро такой системы — искусственная нейронная сеть [7]. Каждая система автомобиля, добавленная в ИСППР, выступает как подсистема из узлов и деталей, имеющая собственную архитектуру.

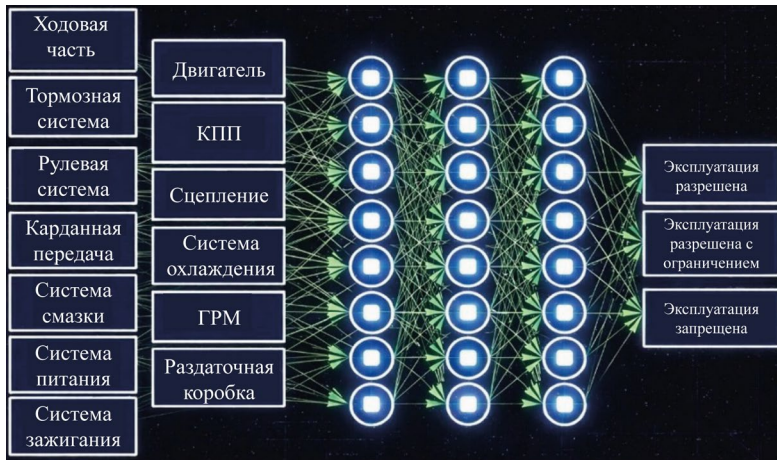


Рис. 1. Интеллектуальная система оценки технического состояния автомобиля³

Выделено 13 основных систем автомобильной техники для загрузки во входной слой нейронной сети. Чтобы заставить такую расширенную модель ИНС комплексно оценивать техническое состояние машины необходимо достаточное количество обучающих выборок опытных эксплуатационных данных [8]. Для этого нужно знать степень повреждения каждой детали (узла) из каждой системы, представленной на рис. 1. От количества обучающих выборок зависит производительность сети, по которой можно судить о качестве ИНС. Сложно сразу получить такой объем опытных данных по всем системам автомобильной техники, поэтому было решено использовать свойство нейронной сети дообучаться и переобучаться. Это позволило действовать по принципу «от общего к частному». «Частное» в данном случае — оценка технического состояния отдельно взятой или нескольких взаимосвязанных систем, а «общее» — комплексная оценка технического состояния машины.

Сделаем важное замечание. На рис. 1 представлены 13 систем автомобиля, и в теоретическую модель заложен учет психоэмоционального состояния водителя, однако на текущем этапе разработки и валидации модели в обучающей выборке — 8 ключевых параметров, относящихся к ходовой части (рама, мосты, подвеска и т.д.). Это решение обусловлено двумя факторами. Во-первых, согласно предварительному анализу чувствительности, именно параметры ходовой части (рамы X_1 и мостов X_2) вносят наибольший вклад в итоговую оценку безопасности. Во-вторых, объем размеченных и верифицированных данных по тормозной и рулевой системам недостаточен для полноценного обучения. Информация по этим системам, а также по другим узлам из 13 зарезервирована для расширения базы данных и является предметом будущих научных изысканий.

Таким образом, разработана оценка технического состояния ходовой части машины (рис. 2).




Рис. 2. Модель ИНС оценки технического состояния ходовой части: X_1 — рама; X_2 — мосты; X_3 — передняя подвеска; X_4 — задняя подвеска; X_5 — колеса и ступица; X_6 — направляющие элементы; X_7 — крепежные элементы; X_8 — дополнительные элементы.

³ КПП — коробка переключения передач. ГРМ — газораспределительный механизм.

Во входной слой искусственной нейронной сети к браковочным показателям и эксплуатационным факторам для комплексной оценки технического состояния машины добавили показатели, отражающие компетенцию специалистов по ремонту и обслуживанию, а также условия эксплуатации и психоэмоциональное состояние водителя или же его личный психотип.

В выходном слое ИНС участвуют нейроны, отражающие техническое состояние автомобиля, вероятность возникновения аварийной ситуации (отказа) или невыполнения поставленной задачи из-за отказа [9].

Детали из связанных нейронной сетью систем взаимосвязаны и в реальных условиях эксплуатации [10]. Например, повреждение сайлентблока переднего рычага влияет на другие элементы подвески из-за зазоров и дополнительных динамических нагрузок при эксплуатации. В связи с этим детали определенных систем и узлов классифицировали по степени влияния на безопасность эксплуатации и на риск аварии, а также определили взаимосвязанные детали подвески, рулевой и тормозной систем (рис. 3).

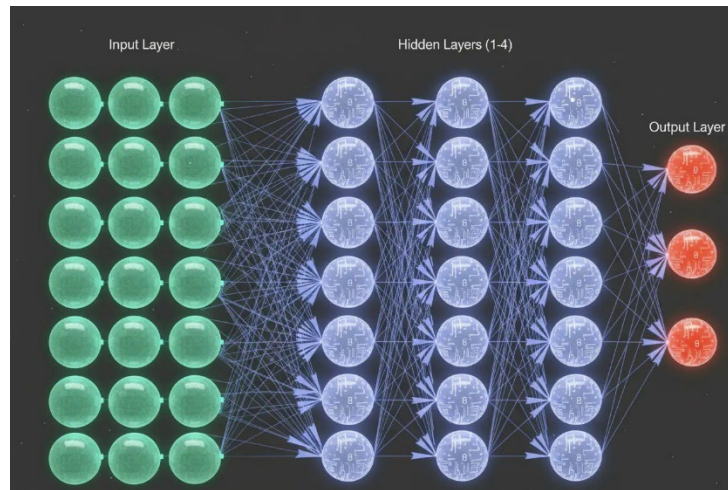


Рис. 3. Модель ИНС, включающая ходовую, тормозную и рулевую системы автомобиля⁴

Были учтены браковочные показатели следующих систем:

- ходовая — рама, мосты, колеса, рычаги, амортизаторы, пружины, сайлентблоки;
- тормозная — компрессор, ресиверы, тормозные камеры, цилиндры, энергоаккумуляторы, ножной тормозной кран, тормозные диски (барабаны), тормозные колодки;
- рулевая — колонка, рейка, усилитель, тяги, наконечники.

Для обучения ИНС использовалась информация о типовых дефектах, статистике отказов и причинах отказов деталей вышеперечисленных систем. Задействовали также данные, полученные с помощью других нейронных сетей [11]. Это позволило работать с такими источниками, как сайты автопроизводителей, руководства по эксплуатации машин, нормативные документы, автомобильные форумы, научная литература. Полученная таким образом информация формализовалась в удобную для обучения сети форму [12].

В качестве базовой модели выбрали нейронную сеть прямого распространения — многослойный перцептрон (MLP). Для определения оптимальной архитектуры построили и обучили три сети с различной конфигурацией. Ниже — их описание.

– MLP 8-8-3: 8 входных нейронов, 8 скрытых, 3 выходных. Алгоритм обучения: BFGS. Функция ошибки — сумма квадратов. Функция активации скрытых нейронов — гиперболическая, выходных — экспонента.

– MLP 8-24-3: 8 входных нейронов, 24 скрытых (распределенных по трем слоям), 3 выходных. Алгоритм обучения: BFGS. Функция активации скрытых и выходных нейронов — логистическая.

– MLP 8-19-3: 8 входных нейронов, 19 скрытых, 3 выходных. Алгоритм обучения: BFGS. Функция активации скрытых нейронов — логистическая, выходных — тождественная.

Результаты исследования. Массив данных для обучения нейронной сети состоит из ста обучающих выборок (табл. 1). Каждая получена из статистических и опытных данных опросных листов специалистов Центра обслуживания и ремонта автомобильной техники ДГТУ. Кроме того, использовали искусственные нейронные сети из интернета для работы с большими данными.

⁴ Input layer — входной слой, hidden layers — скрытые слои, output layer — выходной слой.

Выборки для обучения нейронной сети

№ п/п	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	Y
1	26	7	18	5	12	22	4	5	2
2	40	23	29	86	5	62	0	87	3
3	0	77	57	5	0	20	0	0	2
4	5	90	10	5	2	20	0	8	2
5	44	0	20	5	73	0	23	0	2
6	33	18	90	15	0	17	0	60	3
7	0	0	0	21	40	0	6	10	1
8	0	2	92	13	0	67	0	16	2
9	85	29	10	3	84	0	10	0	3
10	27	39	25	0	0	32	0	19	2
...
20	0	0	69	49	25	15	0	0	2
30	0	13	0	12	0	54	0	76	3
40	12	11	32	65	34	23	29	1	1
...
100	74	76	1	38	20	33	41	48	3

Как и на рис. 2, здесь X₁ — рама, X₂ — мосты, X₃ — передняя подвеска, X₄ — задняя подвеска, X₅ — колеса и ступица, X₆ — направляющие элементы, X₇ — крепежные элементы, X₈ — дополнительные элементы. К деталям рамы отнесли непосредственно раму, лонжероны и поперечины. К мостам — передний и средний мост, главную передачу, дифференциал, межосевой дифференциал, механизм блокировки, задний мост. Детали передней подвески: рессоры, амортизаторы, башмаки рессор с втулками, реактивные штанги. Детали задней подвески: рессоры, балансирующие механизмы, башмаки балансира, амортизаторы. Колеса и ступицы: колеса дисковые с шинами, ступицы передних и задних колес, гайки крепления колес. Направляющие элементы: поворотные кулаки, втулки поворотных кулаков, шкворни, втулки шкворней, тяги. Крепежные элементы: стремянки рессор, гайки стремянок, втулки стремянок, крепежные болты, кронштейны. Дополнительные элементы: стабилизаторы поперечной устойчивости, сайлентблоки, опоры подвески, крепежные кронштейны.

Выходной параметр Y обозначает одну из трех категорий: 1 — эксплуатация разрешена, 2 — эксплуатация разрешена с ограничением, 3 — эксплуатация запрещена.

Построили три искусственные нейронные сети с разной архитектурой. Входной и выходной слои одинаковые, количество нейронов в скрытых слоях разное. Отличаются такие параметры, как алгоритм обучения, функция ошибки, функция активации скрытых нейронов, функция активации выходных нейронов [13]. Заданные параметры и результаты обучения по трем построенным нейронным сетям обобщаются в табл. 2.

Таблица 2

Параметры и результаты обучения по трем нейронным сетям

№	Архитектура	Производительность			Алгоритм обучения	Функция ошибки	Функция активации нейронов	
		Обучение	Контроль	Тесты			скрытых	выходных
1	MLP 8-8-3	90,00	90,00	80,00	BFGS 20	Сумма квадратов	Гиперболическая	Экспонента
2	MLP 8-24-3	93,75	80,00	90,00	BFGS 14		Логистическая	Логистическая
3	MLP 8-19-3	91,25	80,00	90,00	BFGS 26		Логистическая	Тождественная

Лучшую сеть выбирали по трем критериям производительности: при обучении, контроле и тестировании. Для каждой сети взяли одинаковые массивы данных (обучающие выборки). Часть использованного массива представлена в табл. 1. Сто выборок предварительно разделили на восемьдесят обучающих, десять контрольных и десять тестовых.

Как видно из табл. 2, оптимальная из трех — нейронная сеть MLP 8-24-3. Архитектура 8-24-3 указывает на 8 нейронов во входном слое, 24 — в скрытом (по 8 в каждом из трех слоев) и 3 — в выходном. В табл. 3 представлены итоги классификации по категориям технического состояния автомобиля для нейронной сети MLP 8-24-3.

Таблица 3

Классификация технического состояния автомобиля для нейронной сети MLP 8-24-3

MLP 8-24-3	Категория 1	Категория 2	Категория 3	Все
Все	25	38	17	80
Правильно	25	36	14	75
Неправильно	0	2	3	5
Правильно (%)	100,00	94,736	82,352	93,750
Неправильно (%)	0,0000	5,263	17,647	6,250

Из 25 обучающих выборок 1-й категории нейронная сеть правильно классифицировала все 25 (производительность — 100 %). По 2-й категории нейросеть из 38 обучающих выборок лишь две классифицировала неверно (производительность почти 95 %). По 3-й категории технического состояния сеть показала производительность 82 %.

Далее приводится анализ чувствительности модели MLP 8-24-3 к изменению входных параметров сети. В табл. 4 представлен ранжированный перечень нейронов входного слоя сети по степени влияния на итоговую классификацию технического состояния.

Таблица 4

Ранжирование нейронов входного слоя по степени влияния на классификацию технического состояния автомобиля

Ранг	1	2	3	4	5	6	7	8
Нейроны	X ₁	X ₂	X ₇	X ₅	X ₈	X ₄	X ₆	X ₃
Чувствительность	2,072	1,603	1,599	1,585	1,533	1,485	1,449	1,280

В табл. 5 приводятся доверительные уровни определения технического состояния автотранспортного средства для 10 контрольных и десяти тестовых выборок. Значения в трех последних столбцах таблицы — это уровни активации трех нейронов выходного слоя сети при ее работе по каждой выборке данных. Наибольшее значение уровня активации одного из трех нейронов и является доверительным уровнем.

Таблица 5

Доверительные уровни определения технического состояния автомобиля

№ выборки	Целевая	Выходная	Категория 1	Категория 2	Категория 3
14	1	1	0,531420	0,273081	0,195499
15	1	1	0,386258	0,359916	0,253826
16	1	1	0,576008	0,212090	0,211902
17	3	3	0,179771	0,331566	0,488663
18	2	2	0,278165	0,431201	0,290633
19	3	3	0,198094	0,267284	0,534623
20	2	2	0,241999	0,516263	0,241739
21	2	1	0,568989	0,221012	0,209999
22	1	1	0,574172	0,214602	0,211226
23	2	2	0,269398	0,460988	0,269615
91	2	2	0,208055	0,550675	0,241270
92	3	3	0,157003	0,419964	0,423034
93	2	1	0,493552	0,311828	0,194619
94	3	3	0,200722	0,263546	0,535731
95	2	2	0,211775	0,574774	0,213451
96	3	3	0,245410	0,275353	0,479237
97	2	2	0,260837	0,469146	0,270018
98	3	3	0,174727	0,350631	0,474642
99	3	2	0,253433	0,483170	0,263396
100	3	3	0,241020	0,304389	0,454591

Здесь с 91-й по 100-ю — контрольные выборки. Они применяются во время обучения для настройки параметров модели. С 14-й по 23-ю — тестовые выборки для итоговой проверки качества нейронной сети. Из десяти контрольных выборок нейронная сеть неправильно классифицировала две:

- в 93-й вместо 2-й категории (эксплуатация разрешена с ограничением) получили 1-ю (эксплуатация разрешена без ограничений);
- в 99-й вместо 3-й категории (эксплуатация запрещена) получили 2-ю категорию.

Из десяти тестовых выборок нейронная сеть неправильно классифицировала лишь одну — 21-ю. Вместо 2-й категории получили 1-ю.

Эти три ошибки в таблице выделены красным цветом.

Необходимо было получить основные описательные статистики значений доверительных уровней определения технического состояния машины для ста выборок. С этой целью данные обработали нормальным законом распределения, построили гистограмму и график плотности распределения (рис. 4).




Рис. 4. Гистограмма распределения доверительных уровней оценки технического состояния автомобиля

Обсуждение. Результаты исследования подтверждают эффективность применения многослойного перцептрона для решения задачи комплексной оценки технического состояния автомобиля. Адекватность и способность к обобщению модели MLP 8-24-3 доказывает высокая точность классификации (93,75 % на обучении, 90 % на тесте). Полученные значения точности по категориям логично интерпретировать в контексте сложности диагностики: категория «эксплуатация запрещена» (82,35%) может включать пограничные или сложно комбинированные случаи повреждений, требующие более детального анализа.

Для обучения использовались метод BFGS, функция ошибки суммы квадратов и различные функции активации. Наилучшие результаты показала сеть MLP 8-24-3 с производительностью обучения 93,75 %, контрольной — 80 % и тестовой — 90 %. Анализ результатов классификации сети MLP 8-24-3:

- для категории 1 («эксплуатация разрешена») точность составила 100 %;
- для категории 2 («эксплуатация разрешена с ограничениями») — 94,74 %;
- для категории 3 («эксплуатация запрещена») — 82,35 %.

Выявленное с помощью анализа чувствительности доминирующее влияние параметров рамы (X1) и мостов (X2) на итоговое решение системы согласуется с инженерной практикой, поскольку это элементы несущей основы, и они критически важны для безопасности. Таким образом, нейросеть не только эффективно классифицирует состояния, но и выявляет внутренние, логически обоснованные зависимости между входными данными, что сближает ее работу с экспертными рассуждениями.

Представленное исследование показало, что весовые коэффициенты и синаптические связи обученной ИНС могут служить количественной мерой взаимного влияния деталей различных систем на общую безопасность [14]. Этот важный теоретический результат открывает возможности для использования подобных моделей не только как инструментов классификации, но и как средств для анализа структурной целостности и уязвимостей сложных технических систем.

Разработанная система выходит за рамки существующих решений, фокусирующихся на отдельных агрегатах, и предлагает интегрированный подход. У него, однако, есть и ограничения. Они связаны с объемом обучающей выборки (100 примеров). Хотя использованный метод дообучения сети позволил компенсировать этот недостаток, для повышения устойчивости и точности модели, особенно по 3-й категории, требуется расширение базы данных за счет большего количества реальных диагностических случаев.

Перспективные направления дальнейших исследований:

- увеличение и диверсификация обучающего массива, эксперименты с другими архитектурами ИНС (например, сверточными или рекуррентными сетями для анализа временных рядов параметров);
- интеграция системы в реальный диагностический комплекс с обратной связью от экспертов для непрерывного улучшения модели.

Заключение. Подтвердилась эффективность применения ИНС для разработки интеллектуальной системы поддержки принятия решений, которая комплексно оценивает техническое состояние автомобиля. В работе не только достигнута высокая точность классификации (до 100 % по отдельным категориям), но и показан принципиально важный результат: нейросетевая модель способна выявлять и количественно оценивать скрытые связи между состоянием различных систем автомобиля, что напрямую влияет на безопасность эксплуатации.

Практическая значимость исследования заключается в создании прототипа интеллектуальной системы поддержки принятия решений, позволяющей автоматизировать процесс оценки технического состояния транспортного средства.

Моделирование показало, что разработанная система обеспечивает повышение точности классификации технического состояния до 90 % на тестовой выборке, а также позволяет сократить время принятия диагностического решения на 30–40 % по сравнению с традиционным экспертным подходом. Дополнительно применение системы снижает влияние субъективного фактора при оценке состояния техники, что особенно важно для работы с комплексными и взаимосвязанными отказами. В перспективе это может привести к сокращению эксплуатационных затрат и повышению уровня безопасности эксплуатации транспортных средств.

Предложенная система обладает потенциалом для внедрения в диагностические комплексы сервисных центров [15], а также для использования в учебном процессе при подготовке специалистов в области технической эксплуатации автомобилей. Дальнейшее развитие работы, направленное на расширение базы знаний и оптимизацию алгоритмов, позволит повысить точность и надежность системы, приблизив ее к уровню принятия решений высококвалифицированным экспертом.

Список литературы / References

1. Машошин О.Ф., Гусейнов Г. Разработка комплексного алгоритма обработки диагностических параметров авиационных ГТД на основе многослойных нейронных сетей. *Контроль. Диагностика.* 2025;7:41–54. <https://doi.org/10.14489/td.2025.07.pp.041-054>

Mashoshin OF, Huseynov H. Development of an Integrated Algorithm for Processing Aircraft GTE Diagnostic Parameters using Multilayer Neural Networks. *Testing. Diagnostics.* 2025;7:41–54. (In Russ.) <https://doi.org/10.14489/td.2025.07.pp.041-054>

2. Химченко А.В., Мищенко Н.И., Савчук О.В. Оценка возможности применения искусственных нейронных сетей для самодиагностики двигателя внутреннего сгорания с отключением цилиндров. *Тракторы и сельскохозяйственные машины.* 2022;89(3):175–186. <https://doi.org/10.17816/0321-4443-106169>

Khimchenko AV, Mishchenko NI, Savchuk OV. Evaluation of the Possibility of Using Artificial Neural Networks for Self-Diagnosis of an Internal Combustion Engine with Cylinder Deactivation. *Tractors and Agricultural Machinery.* 2022;89(3):175–186. (In Russ.) <https://doi.org/10.17816/0321-4443-106169>

3. Болдин А.П., Юрковский И.М., Постолиит А.В. Возможность повышения эффективности диагностирования двигателей автомобилей БЕЛАЗ по параметрам работавшего масла на основе комплексного применения модулей программы Statistica «дискриминантный, кластерный анализы» и «нейронные сети». *Вестник Московского автомобильно-дорожного государственного технического университета (МАДИ).* 2017;3:10–16. URL: https://www.elibrary.ru/download/elibrary_29896416_33362100.pdf (дата обращения: 23.04.2026).

Boldin AP, Yurkovski IM, Postolite AV. The Opportunity of Improving Effectiveness of BELAZ Engine Diagnostics According to Parameters of Used oil and Based on Integrated Application of Statistica Modules “Discriminant, Cluster Analysis” and “Neural Networks”. *Moscow Automobile and Road Construction State Technical University (MADI) Bulletin.* 2017;3:10–16. (In Russ.) URL: https://www.elibrary.ru/download/elibrary_29896416_33362100.pdf (accessed: 23.04.2026).

4. Колпаков В.Е. Искусственный интеллект в определении технического состояния диагностируемого объекта. *Известия Санкт-Петербургского государственного аграрного университета*. 2014;36:263–270. URL: <https://www.elibrary.ru/item.asp?id=24832580> (дата обращения: 23.04.2026).

Kolpakov VE. Employment of Artificial Intelligence to Determine Object Technical State. *Izvestiya Saint-Petersburg State Agrarian University*. 2014;36:263–270. (In Russ.) URL: <https://www.elibrary.ru/item.asp?id=24832580> (accessed: 23.04.2026).

5. Grigoriev MV. Application of a Comprehensive Monitoring System for the Technical Condition of Vehicles to Improve Their Operational Reliability. *Science Journal of Transportation*. 2025;1(21):28–35. URL: <https://www.elibrary.ru/item.asp?id=82586382> (accessed: 23.04.2026).

6. Хван Р.В. Сравнительный анализ качества работы искусственных нейронных сетей для оценки технического состояния стальных канатов. *Безопасность техногенных и природных систем*. 2024;2:68–77. <https://doi.org/10.23947/2541-9129-2024-8-2-68-77>

Khvan RV. Comparative Analysis of the Performance of Artificial Neural Networks in Assessing the Technical Condition of Steel Ropes. *Safety of Technogenic and Natural System*. 2024;2:68–77. <https://doi.org/10.23947/2541-9129-2024-8-2-68-77>

7. Ming Jin, Huan Yee Koh, Qingsong Wen, Zambon D, Alippi C, Webb GI, et al. A Survey on Graph Neural Networks for Time Series: Forecasting, Classification, Imputation, and Anomaly Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)*. 2024;12(46):10466–10485. URL: <https://arxiv.org/abs/2307.03759> (accessed: 23.04.2026).

8. До Ф.Х., Ле Ч.Д., Берёзкин А.А., Киричек Р.В. Графовые нейронные сети для классификации трафика в каналах спутниковой связи: сравнительный анализ. *Труды учебных заведений связи*. 2023;9(3):14–27. <https://doi.org/10.31854/1813-324X-2023-9-3-14-27>

Do PH, Le TD, Berezkin A, Kirichek R. Graph Neural Networks for Traffic Classification in Satellite Communication Channels: A Comparative Analysis. *Proceedings of Telecommunication Universities*. 2023;9(3):14–27. <https://doi.org/10.31854/1813-324X-2023-9-3-14-27>

9. Есипов Д.А. Подход к обнаружению неконвенциональной пиксельной атаки на нейронные сети обработки изображений методами статистического анализа. *Научно-технический вестник информационных технологий, механики и оптики*. 2024;24(3):490–499. <https://doi.org/10.17586/2226-1494-2024-24-3-490-499>

Esipov DA. An Approach to Detecting L0-Optimized Attacks on Image Processing Neural Networks via Means of Mathematical Statistics. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*. 2024;3(24):490–499. (In Russ.) <https://doi.org/10.17586/2226-1494-2024-24-3-490-499>

10. Пименов В.И., Пименов И.В. Интерпретация обученной нейронной сети на основе генетических алгоритмов. *Информационно-управляющие системы*. 2020;6:12–20. <https://doi.org/10.31799/1684-8853-2020-6-12-20>

Pimenov VI, Pimenov IV. Interpretation of a Trained Neural Network Based on Genetic Algorithms. *Information and Control Systems*. 2020;6:12–20. (In Russ.) <https://doi.org/10.31799/1684-8853-2020-6-12-20>

11. Хван Р.В. Комплексная оценка технического состояния надземных рельсовых крановых путей с использованием искусственных нейронных сетей. *Безопасность труда в промышленности*. 2025;6:7–13. <https://doi.org/10.24000/0409-2961-2025-6-7-13>

Khvan RV. Comprehensive Evaluation of the Technical State of Overhead Railway Crane Tracks Using Artificial Neural Networks. *Occupational Safety in Industry*. 2025;6:7–13. (In Russ.) <https://doi.org/10.24000/0409-2961-2025-6-7-13>

12. Панфилов А.В., Николаев Н.Н., Юсупов А.Р., Короткий А.А. Интегральная оценка риска при диагностике стальных канатов с использованием компьютерного зрения. *Безопасность техногенных и природных систем*. 2023;1:56–69. <https://doi.org/10.23947/2541-9129-2023-1-56-69>

Panfilov AV, Nikolaev NN, Yusupov AR, Korotkiy AA. Integral Risk Assessment in Steel Ropes Diagnostics Using Computer Vision. *Safety of Technogenic and Natural Systems*. 2023;1:56–69. <https://doi.org/10.23947/2541-9129-2023-1-56-69>

13. Шабля В.О., Коноваленко С.А., Орлов Е.О., Галямин Н.А. Методы семантического анализа на основе моделей машинного обучения с использованием искусственных нейронных сетей. *Наука и реальность*. 2025;1:113–122. URL: [https://zhurnalnir.ru/doc/publ/1\(21\)2025-2.pdf](https://zhurnalnir.ru/doc/publ/1(21)2025-2.pdf) (дата обращения: 23.04.2026).

Shablya VO, Konovalenko SA, Orlov EO, Galyamin NA. Methods of Semantic Analysis Based on Machine Learning Models Using Artificial Neural Networks. *Science & Reality*. 2025;1:113–122. (In Russ.) URL: [https://zhurnalnir.ru/doc/publ/1\(21\)2025-2.pdf](https://zhurnalnir.ru/doc/publ/1(21)2025-2.pdf) (accessed: 23.04.2026).

14. Хазиев М.Л. Диагностика надежности гидравлического привода с применением нейронных сетей. *Социально-экономические и технические системы: исследование, проектирование, оптимизация*. 2025;1:114–122. URL: <https://seats.elpub.ru/jour/article/view/179> (дата обращения: 23.04.2026).

Khaziev ML. Diagnostics of Hydraulic Drive Reliability Using Neural Networks. *Social-Economic and Technical Systems: Research, Design and Optimization*. 2025;1:114–122. (In Russ.) URL: <https://seats.elpub.ru/jour/article/view/179> (дата обращения: 23.04.2026).

15. Ерохин В.В., Зафиров А.Е. Повышение качества разработки программного обеспечения для технических объектов машиностроения на основе нейронных суррогатов. *Мехатроника, автоматика и робототехника*. 2025;15:89–92. <https://doi.org/10.26160/2541-8637-2025-15-89-92>

Erokhin VV, Zafirov AE. Improving The Quality Of Software Development For Technical Objects Of Mechanical Engineering Based On Neural Surrogates. *Mechatronics, Automation and Robotics*. (In Russ.) 2025;15:89–92. <https://doi.org/10.26160/2541-8637-2025-15-89-92>

Об авторе

Роман Владимирович Хван, кандидат технических наук, доцент кафедры «Эксплуатации транспортных систем и логистики» Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [ORCID](#), [SPIN-код](#), [ResearcherID](#), [ScopusID](#), khvanroman@yandex.ru

Конфликт интересов, автор заявляет об отсутствии конфликта интересов.

Автор прочитал и одобрил окончательный вариант рукописи.

About the Author:

Roman V. Khvan, Cand. Sci. (Eng.), Associate Professor of the Department of Operation of Transport Systems and Logistics, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [ORCID](#), [SPIN-code](#), [ResearcherID](#), [ScopusID](#), khvanroman@yandex.ru

Conflict of Interest Statement: the author declares no conflict of interest.

The author has read and approved the final version of manuscript.

Поступила в редакцию / Received 25.12.2025

Поступила после рецензирования / Reviewed 10.03.2026

Принята к публикации / Accepted 17.03.2026