

МАШИНОСТРОЕНИЕ И МАШИНОВЕДЕНИЕ

MACHINE BUILDING AND MACHINE SCIENCE



УДК 621.86

Оригинальное эмпирическое исследование

<https://doi.org/10.23947/2687-1653-2026-26-3-2435>

Контроль технического состояния подъемных сооружений и оборудования с использованием искусственных нейронных систем

Р.В. Хван , А.А. Короткий 

Донской государственный технический университет, г. Ростов-на-Дону,
Российская Федерация, <https://ror.org/00x5je630>

✉ khvanroman@yandex.ru

EDN: PSBRHA

Аннотация

Введение. Федеральные нормы и правила в области промышленной безопасности регламентируют порядок проведения оценки технического состояния указанных технических устройств и сопутствующего оборудования. Однако данные регуляторные требования предусматривают проведение дискретного анализа дефектов отдельных узлов и деталей грузоподъемных машин. Подобный подход не всегда обеспечивает требуемую точность и эффективность при диагностировании общего состояния оборудования, так как разнообразные сочетания дефектов в многочисленных конструктивных элементах предопределяют различную степень их совокупного износа. Это обусловлено тем, что в ходе долговременной эксплуатации составные узлы и детали механизмов подвергаются неравномерному деструктивному воздействию, приводящему к вариативности степени их разрушения. В настоящем исследовании предлагается сформировать комплекс научно-технических мер, направленных на повышение эксплуатационной надежности как самих грузоподъемных машин, так и сопряженного оборудования, посредством интеграции современных интеллектуальных алгоритмов. Цель работы — разработка интеллектуальной системы поддержки принятия решений, предназначенной для комплексной интегральной оценки технического состояния подъемных сооружений.

Материалы и методы. Для достижения поставленной цели были разработаны три архитектуры искусственных нейронных сетей. Первая модель характеризуется пятислойной структурой: первый — входной слой включает восемь нейронов, соответствующих аналогичному числу браковочных показателей элементов подъемных сооружений, таких как дефекты ходовой части, тормозной системы, канатно-блочной системы и грузового крюка. Три последующих скрытых слоя содержат по восемь нейронов каждый, обеспечивая процесс обучения и фиксацию промежуточных результатов. Выходной слой состоит из трех нейронов, каждый из которых характеризует определенный класс технического состояния исследуемого объекта. Вторая нейронная сеть имеет аналогичную конфигурацию, за исключением входного слоя, в который дополнительно включено девять нейронов, соответствующих показателям браковки несущих металлоконструкций подъемных сооружений. Входной слой третьей модели содержит двадцать девять нейронов. Подобная структура позволяет комплексно оценивать состояние оборудования по всей совокупности браковочных показателей. Практическая реализация разработанных моделей выполнена в среде программирования Python с использованием библиотеки машинного обучения Scikit-learn. Тестирование работоспособности и эффективности разработанных сетей проводилось на десяти независимых выборках по критериям их производительности и доверительным интервалам оценки состояния технических устройств.

Результаты исследования. Производительность разработанных моделей в ходе тестирования составила 100 %, то есть каждая из трех нейросетевых структур безошибочно классифицировала состояние подъемных сооружений во всех десяти тестовых сценариях. При этом доверительный уровень выносимого суждения возрастал по мере масштабирования числа входных параметров сети в диапазоне от 0,628 до 0,705.

Обсуждение. Представленные данные демонстрируют выраженное влияние архитектуры искусственной нейросети на прецизионность диагностирования подъемных сооружений. Ключевым результатом является установление численной зависимости между комбинациями браковочных критериев и результирующим классом со-

стояния посредством анализа уровней активации нейронов выходного слоя, выступающих количественной мерой достоверности принимаемого моделью решения. Полученные выводы коррелируют с предшествующими исследованиями в области приложения методов машинного обучения к технической диагностике. Специфика предложенного подхода состоит в интегральной оценке общего состояния без детального математического моделирования локальных физических процессов, что обуславливает его эффективность в условиях дефицита априорной информации об эксплуатационных режимах. К числу ограничений работы следует отнести относительно небольшой объем выборки и определенную субъективность экспертной разметки. Возможные погрешности обусловлены риском переобучения нейросети на малых массивах обучающей информации.

Заключение. Предложенная интеллектуальная система разработана с учетом практического опыта эксплуатации подъемных машин, анализа накопленных статистических данных и требований действующих отраслевых стандартов. Научные результаты расширяют представление о потенциале применения алгоритмов искусственного интеллекта для обеспечения техногенной безопасности сложных технических объектов. Внедрение подобных систем позволит инженерно-техническому персоналу, не обладающему обширным практическим опытом натурального обследования конструкций, принимать квалифицированные и обоснованные решения относительно возможности продолжения безопасной эксплуатации оборудования.

Ключевые слова: подъемные сооружения, искусственные нейронные сети, степень повреждения, браковочные показатели, комбинация дефектов, оценка технического состояния

Благодарности. Авторы выражают искреннюю благодарность коллективу ООО ИКЦ «Мысль» НГТУ г. Новочеркасска за предоставленную возможность использовать данные экспертизы промышленной безопасности подъемных сооружений, а также за доступ к статистической базе данных типовых повреждений кранов.

Для цитирования. Хван Р.В., Короткий А.А. Контроль технического состояния подъемных сооружений и оборудования с использованием искусственных нейронных систем. *Advanced Engineering Research (Rostov-on-Don)*. 2026;26(3):2435. <https://doi.org/10.23947/2687-1653-2026-26-3-2435>

Original Empirical Research

Technical Condition Monitoring of Lifting Structures and Equipment Using Artificial Neural Systems

Roman V. Khvan , Anatoly A. Korotky 

Don State Technical University, Rostov-on-Don, Russian Federation, <https://ror.org/00x5je630>

 khvanroman@yandex.ru

Abstract

Introduction. Federal industrial safety standards and regulations establish the requirements for the technical condition assessment of the said engineering devices and associated equipment. However, these regulatory frameworks require a discrete-level defect analysis of composite nodes and parts of load-lifting machinery. This approach does not always ensure the required accuracy and objectivity in monitoring the overall condition of equipment, as various combinations of defects in numerous structural components determine varying degrees of their overall wear. This is due to the fact that, during long-term operation, the components and parts of the mechanisms are subject to uneven destructive stress resulting in variability in the degree of their damage. The present work proposes a combination of scientific and technical measures to improve the operational reliability of both lifting machines and associated equipment through the integration of modern intelligent algorithms. The research objective of the study is to develop an intelligent decision support system designed for a comprehensive, integrated assessment of the operating conditions of lifting structures.

Materials and Methods. To achieve this objective, three models of artificial neural networks have been developed. The first model contains five layers: the first input layer includes eight neurons corresponding to the same number of rejection indicators of lifting structure components, such as defects in the undercarriage, braking system, rope-and-pulley system, and load hook. The three subsequent hidden layers contain eight neurons each. They are responsible for the learning process of the network and provide recording of intermediate results. The output layer consists of three neurons, each of which characterizes a certain class of technical condition of the object under study. The second neural network has a similar configuration, except for the input layer, which additionally includes nine neurons corresponding to the rejection indicators of the supporting metal structures of lifting facilities. The input layer of the third model contains twenty-nine neurons. This structure allows for a comprehensive assessment of equipment condition across a full range of rejection indicators. The practical implementation of the developed models was performed in the Python programming environment using the Scikit-learn machine learning library. Testing of the performance and efficiency of the developed

networks was carried out on ten independent samples according to their performance criteria and confidence intervals for assessing the state of engineering devices.

Results. The performance of the developed models under testing was 100%, meaning each of the three neural network structures accurately classified the conditions of the lifting structures in all ten test scenarios. Moreover, the confidence level of the judgments made increased as the number of network input parameters was scaled in the range from 0.628 to 0.705.

Discussion. The presented data demonstrate the significant impact of the artificial neural network architecture on the precision of lifting structure diagnostics. The key result is the establishment of a numerical relationship between combinations of rejection criteria and the resulting condition class through the analysis of the activation levels of output layer neurons, which serve as a quantitative measure of the reliability of the decision made by the model. The findings correlate with previous research in the field of applying machine learning methods to technical diagnostics. The specificity of the proposed approach is in the integrated assessment of the overall condition without detailed mathematical modeling of local physical processes, which determines its efficiency under conditions of limited a priori information about operational modes. Limitations of the work include a relatively small sample size and a certain subjectivity of expert marking. Possible errors are due to the risk of retraining the neural network on small arrays of training information.

Conclusion. The proposed intelligent system is developed taking into account practical experience in operating lifting machines, analysis of accumulated statistical data, and the requirements of current industry standards. Scientific results expand the understanding of the potential of using artificial intelligence algorithms to ensure the technological safety of complex technical objects. The implementation of such systems will allow engineering and technical personnel who do not have extensive practical experience in on-site inspection of structures to make qualified and informed decisions regarding the possibility of continuing the safe operation of equipment.

Keywords: lifting structures, artificial neural networks, degree of damage, rejection indicators, combination of defects, technical condition assessment

Acknowledgments. The authors would like to thank the staff of Scientific and Technical Center “Mysl”, Novocherkassk State Technical University, for the opportunity to use the data of the industrial safety examination of lifting structures, as well as for access to the statistical database of typical crane damage.

For Citation. Khvan RV, Korotky AA. Technical Condition Monitoring of Lifting Structures and Equipment Using Artificial Neural Systems. *Advanced Engineering Research (Rostov-on-Don)*. 2026;26(3):2435. <https://doi.org/10.23947/2687-1653-2026-26-3-2435>

Введение. В соответствии с Приказом Ростехнадзора¹ (далее — ФНП) определены и утверждены браковочные показатели для различных элементов подъемных сооружений (далее — ПС): ходовой части, тормозной и канатно-блочной систем, несущих металлоконструкций, а также болтовых и заклепочных соединений. Тем не менее принятая в настоящее время методология предусматривает изолированную оценку каждого повреждения вне связи с остальными. В реальных условиях эксплуатации конструктивные узлы ПС подвергаются неравномерному износу, вследствие чего множественные сочетания деструктивных факторов способны вызывать синергетический эффект, существенно снижающий фактический запас прочности по сравнению с суммарным воздействием обособленных дефектов [1]. В качестве примера можно привести сочетание остаточного прогиба пролетных балок, составившего 54 мм при нормативном пределе 59,5 мм, и увеличенной доли рабочих циклов с массой груза свыше 0,75Q (5 % вместо регламентированных паспортом 2 %). Подобная совокупность условий обусловила сокращение периода безопасного функционирования технического устройства с расчетных 7 до 1 года, однако методика количественной оценки указанного взаимного влияния в действующих нормативных документах полностью отсутствует. Применяемый сегодня подход не обеспечивает возможности численного учета интерференции разнородных повреждений. Это приводит к возникновению неопределенности при установлении сроков проведения очередного технического освидетельствования — выражающейся либо в избыточной периодичности проверок, либо, что гораздо опаснее, в несвоевременном обнаружении критических состояний оборудования. Описанный недостаток приобретает особую критичность применительно к механизмам, выработавшим нормативный ресурс, поскольку в данном случае даже незначительные на первый взгляд дефекты в своей совокупности способны инициировать катастрофические последствия [2].

Анализ данных, полученных при изучении 50 заключений экспертизы промышленной безопасности грузоподъемных кранов различных типов (башенных, мостовых, козловых, а также подвесных однобалочных), выполненных за 2024–2025 годы, свидетельствует о системном характере проблем, связанных с адекватной оценкой

¹ Об утверждении федеральных норм и правил в области промышленной безопасности «Правила безопасности опасных производственных объектов, на которых используются подъемные сооружения»: Приказ Ростехнадзора от 26.11.2020 №461. URL: https://www.consultant.ru/document/cons_doc_LAW_373321/ (дата обращения: 29.06.2026).

технического состояния ПС [3]. В числе наиболее распространенных деструктивных факторов выделяются: накопление усталостных повреждений металла при циклическом нагружении (36 % от общего объема зарегистрированных нарушений), несоответствие фактического распределения нагрузок нормативным паспортным параметрам (25 %), износ элементов канатно-блочной системы (17 %), а также неисправности гидравлического оборудования (11 %). Систематическим явлением выступает превышение установленной доли рабочих циклов с грузом, превышающим 0,75Q, при эксплуатации машин со сроком службы более 30 лет. В условиях формального отсутствия повреждений, выявляемых методами визуально-измерительного контроля, данное обстоятельство влечет за собой сокращение назначенного периода надежной эксплуатации до 1–2 лет вместо потенциально возможных 3–7 лет. В 27 % рассмотренных случаев безопасный период функционирования был ограничен 1 годом при отсутствии очевидных дефектов несущих систем металлоконструкций, что подтверждает недостаточную репрезентативность применяемых методологий локального анализа [4].

Исследование статистических данных по аварийности и производственному травматизму указывает на то, что ключевыми факторами риска выступают неудовлетворительное качество технического обслуживания, диагностирования и экспертизы промышленной безопасности (обусловленное физическим и моральным износом парка оборудования), прогрессирование дефектов ввиду их несвоевременного обнаружения, а также грубые нарушения производственной и трудовой дисциплины [5]. Типичным примером подобного развития событий служит инцидент с башенным краном КБ-515, при котором смещение и последующий выход металлического пальца крепления стреловых секций в сочетании с неблагоприятными метеорологическими факторами вызвали разрушение соединительного узла и падение стрелы на строящийся объект. Непосредственной причиной произошедшего послужил комплекс взаимосвязанных обстоятельств: разрушение удерживающего буртика пальца, недостаточная эффективность производственного контроля и систематическое невыполнение персоналом должностных инструкций. Локальная оценка износа крепежного элемента без учета его взаимодействия со смежными конструктивными узлами и без детального анализа фактических режимов нагружения крана не позволила своевременно спрогнозировать возникновение предаварийной ситуации.

Альтернативный научно-методический подход, базирующийся на применении аппарата нечеткой логики, изложен в исследовании Э.К. Аблязова и К.А. Аблязова применительно к оценке технического состояния портового подъемно-транспортного оборудования. Предложенный метод ориентирован на функционирование в условиях высокого уровня неопределенности, однако область его внедрения ограничена специфическим типом машин [6].

При этом вне рамок указанных исследований остается задача комплексного одновременного учета разнородных повреждений ключевых узлов грузоподъемных машин, включая ходовую часть, тормозную и канатно-блочную системы, несущие металлоконструкции, а также разъемные и неразъемные соединения. Частные методологические решения, ориентированные, в частности, на прогнозирование потребности в ремонтных воздействиях по комплексу диагностируемых параметров с использованием искусственных нейронных сетей (ИНС), разработаны для авиационной техники [7]. Тем не менее их адаптация к специфическим условиям эксплуатации подъемных сооружений и к регламентированной ФНП² номенклатуре критериев браковки до настоящего времени не проводилась.

Методы нейросетевой диагностики находят активное развитие и в смежных отраслях машиностроительного комплекса. Так, в работе [8] представлен алгоритм обработки диагностических параметров авиационных газотурбинных установок на базе многослойных архитектур. В публикации [9] исследована перспективность интеграции ИНС для самодиагностики двигателей внутреннего сгорания при отключении рабочих цилиндров. Авторами исследования [10] осуществлен анализ надежности гидравлического привода методами нейросетевого моделирования. В исследовании [11] предложено научно обоснованное решение по повышению качества программного обеспечения технических объектов благодаря использованию нейросетевых суррогатов. Перечисленные работы убедительно доказывают высокую эффективность применения нейросетевого аппарата для мониторинга сложных дискретных систем, однако они не ориентированы на решение системной задачи интегральной оценки технического состояния ПС на основе сопоставления всего спектра браковочных критериев.

Таким образом, научный обзор профильной литературы и обобщение результатов экспертиз промышленной безопасности позволяют констатировать отсутствие комплексных интеллектуальных систем поддержки принятия решений, способных оценивать интегральное состояние ПС с учетом взаимного влияния дефектов различной физической природы. В настоящее время не созданы математические нейросетевые модели, охватывающие весь спектр установленных ФНП³ браковочных критериев и обеспечивающие количественное определение достоверности классификационных решений. Существующая практика назначения остаточного ресурса, базирующаяся на изолированной оценке повреждений, не учитывает их синергетические эффекты, что крайне опасно при эксплуатации грузоподъемных машин со значительной наработкой.

² Там же. С. 10–11.

³ Там же. С. 20–21.

Цель данной работы — разработка интеллектуальной системы поддержки принятия решений, предназначенной для комплексной оценки технического состояния грузоподъемных ПС по совокупности нормативных браковочных параметров, установленных ФНП⁴, с использованием механизмов искусственных нейронных сетей.

Для достижения поставленной цели решались следующие задачи:

- систематизация браковочных показателей элементов ПС (ходовой части, тормозной и канатно-блочной систем, металлоконструкций, болтовых и заклепочных соединений) согласно нормативным требованиям и последующее определение структуры входного вектора параметров для нейросетевого анализа;
- разработка трех топологий искусственных нейронных сетей с различным числом входных нейронов (8, 17 и 29 соответственно), обеспечивающих поэтапный учет расширяющейся номенклатуры дефектов — от локальных элементов ПС до сложных несущих систем и соединений;
- формирование представительных обучающих и тестовых выборок на основе верифицированных данных экспертиз промышленной безопасности, подготовленных аттестованными экспертами, с дифференциацией технического состояния по трем основным классам (работоспособное, ограниченно работоспособное, предельное);
- проведение процедур обучения и верификации созданных нейросетевых моделей с оценкой метрик точности классификации и доверительных интервалов принимаемых рекомендаций;
- установление закономерностей влияния размерности пространства входных параметров на верифицируемость оценки технического состояния ПС, а также определение перспектив интеграции разработанных моделей в практику экспертной деятельности в качестве систем поддержки принятия решений.

Материалы и методы. Исходными данными для исследования послужили экспертные заключения о промышленной безопасности 50 грузоподъемных кранов различных типов, подготовленные сотрудниками аккредитованной организации ООО ИКЦ «Мысль» при НГТУ. Каждый отчетный документ содержит акты визуального и измерительного контроля несущих металлоконструкций, протоколы наладки и испытаний приборов безопасности, результаты статических и динамических испытаний, а также ведомости выявленных дефектов. Федеральными нормами и правилами⁵ для каждого диагностического признака определены предельно допустимые величины, превышение которых влечет за собой отбраковку конструктивного элемента либо ограничение последующей эксплуатации оборудования. На основе упомянутых показателей сформированы структуры входных слоев трех проектируемых искусственных нейросетевых моделей, содержащих 8 (x_1 – x_8), 17 (x_1 – x_{17}) и 29 (x_1 – x_{29}) нейронов соответственно.

Визуальный и измерительный контроль осуществлялся с применением следующего комплекта приборов и инструментов: линейка металлическая измерительная 500 мм (цена деления 1 мм); штангенциркуль типа ШЦ-1-125 (диапазон измерений до 125 мм, погрешность $\pm 0,05$ мм); лупы измерительные с увеличением $6\times$ и $10\times$; нивелир оптический GEOBOX N7-36 (точность нивелирования 1 мм/м); шаблон сварщика универсальный УШС-3 и шаблон Ушерова-Маршака; дальномер лазерный Disto-5M (погрешность ± 1 мм); набор щупов №2 (толщина 0,05–1,00 мм); шаблоны радиусные измерительные №1 (R 1–6 мм) и №3 (R 7–25 мм); люксметр Testo 545. Освещенность контролируемых зон составляла не менее 300 лк, а пороговая чувствительность контроля — не хуже 0,15 мм. Весь комплекс используемых средств измерений имел действующие свидетельства о поверке.

В соответствии с требованиями ФНП⁶ оценке подвергались следующие параметры: толщина реборды ходового колеса (мм), диаметр поверхности катания колеса (мм), разность диаметров сопряженных колес (%), износ ручья блока (% от первоначального радиуса), величина выработки ручья барабана (мм), износ зева грузового крюка (% от высоты исходного сечения), износ обода тормозного шкива (% от его толщины), истирание фрикционной накладки (% от толщины); остаточный прогиб пролетных балок (мм), остаточная деформация стержней ферменных конструкций (мм), глубина местных вмятин трубчатых элементов (мм), деформация полок уголков и швеллеров (мм); количество дефектных болтов и заклепок (шт.), зазоры в узловых соединениях (мм), глубина коррозионного поражения металлоконструкций (мм).

Из актов визуального и измерительного контроля для каждого грузоподъемного крана извлекались фактические величины контролируемых параметров. На их основе рассчитывалось отношение фактического показателя к соответствующему предельно допустимому уровню, установленному ФНП⁷, выраженное в процентах. Например, для технического устройства с остаточным прогибом 54 мм при нормативном ограничении в 59,5 мм нормированная входная величина составляет $54/59,5 \times 100 \% = 90,8 \%$. Таким образом, были математически сформированы 29 входных признаков, варьирующих в диапазоне от 0 % (дефект полностью отсутствует) до 100 % (достигнут критический браковочный порог).

⁴ Там же. С. 24–25.

⁵ Там же. С. 27–28.

⁶ Там же. С. 72–73.

⁷ Там же. С. 75–78.

Три специалиста в области промышленной безопасности (обладающие стажем практической работы не менее 10 лет и действующими квалификационными удостоверениями) независимо друг от друга сопоставили каждому из 40 наборов данных один из трех классов технического состояния. В своей оценке они руководствовались требованиями ФНП⁸ и накопленным опытом: класс 1 — работоспособное состояние (период до следующего обследования — 3 года); класс 2 — ограниченно работоспособное (период — 1 год); класс 3 — предельное состояние (эксплуатация технического устройства запрещена). Процедура классификации выполнялась экспертами обособленно, исходные сведения они получали в электронном виде в формате таблиц Excel. Возникавшие расхождения в оценках (составившие менее 10 % от общего объема выборки) устранялись в ходе совместного обсуждения коллегиальным методом консенсуса [12]. Согласованность полученных результатов верифицирована по коэффициенту конкордации Кендалла: $W = 0,87, p < 0,01$.

Из общего массива, включающего 40 наборов данных, методом стратифицированного случайного отбора выделено 30 структурных единиц для обучения и 10 — для тестирования, с сохранением пропорционального соотношения классов. При исследовании каждой из трех предложенных архитектур применялись идентичные обучающие и тестовые множества с соответствующей мерностью входного вектора параметров [13].

В ходе работы были спроектированы три модели многослойного перцептрона с использованием класса MLPClassifier программной библиотеки Scikit-learn (версия 1.0.2). Каждая из данных структур содержит три скрытых слоя по 8 нейронов в каждом со встроенной активационной функцией ReLU, а также выходной слой, состоящий из 3 нейронов с функцией Softmax.

Первая модель (рис. 1) характеризуется наличием входного слоя, состоящего из 8 нейронов, которые соответствуют ключевым браковочным характеристикам ходовой части [14], тормозной и канатно-блочной систем, а также грузового крюка (x_1 – x_8).




Рис. 1. ИНС оценки технического состояния ПС по комбинации браковочных показателей элементов ПС

Вторая модель (рис. 2) имеет входной слой из 17 нейронов, включающий, помимо x_1 – x_8 , дополнительные 9 нейронов для браковочных показателей несущих металлоконструкций (x_9 – x_{17}).




Рис. 2. ИНС для контроля технического состояния ПС с учетом элементов и металлоконструкций ПС

⁸ Там же. С. 79–80.

Третья модель (рис. 3) содержит входной слой из 29 нейронов, соответствующих всем браковочным показателям X_1 – X_{29} , включая дефекты болтовых и заклепочных соединений.




Рис. 3. ИНС для оценки технического состояния ПС, учитывающая комбинацию 29 различных дефектов

Начальные веса инициализированы случайным образом (параметр `random_state = 42` для воспроизводимости). Язык программирования — Python 3.9. Основные библиотеки: `pandas` (1.4.0) и `openpyxl` (3.0.9) для работы с Excel, `sklearn` (1.0.2) для построения и обучения моделей. Входные данные нормализованы методом `MinMaxScaler` к диапазону $[0, 1]$. Параметры обучения: оптимизатор — `Adam`; скорость обучения — 0,001 (по умолчанию); количество эпох — 2000; размер мини-пакета — 10 (соответствует объёму обучающей выборки). Обучение выполнено на персональном компьютере с процессором Intel Core i7-10750H (2,6 ГГц), RAM 16 ГБ, ОС Windows 10 Pro. Время обучения каждой модели составило менее 5 секунд.

Результаты исследования. Обучающие данные загружены из файла Excel, структура которого соответствует заданным требованиям (таблица 1).

Таблица 1

Обучающие выборки (представлены частично) ИНС (x_1 – x_8)

№ п/п	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	y
1	15	32	0	0	22	0	0	0	1
2	31	19	0	61	0	3	0	23	2
3	0	39	0	28	0	0	32	12	2
4	0	0	0	0	9	4	0	0	1
5	79	16	21	16	0	0	0	60	2
6	0	13	0	0	5	0	25	0	1
7	21	33	45	17	0	40	0	0	2
8	70	0	67	0	0	8	0	84	3
9	0	0	15	0	0	0	0	0	1
10	81	0	0	0	0	75	0	0	2
...	...	...	...	...	...	...	...	...	...
30	45	10	75	0	20	0	0	1	2

Результатом работы ИНС является правильно определенное техническое состояние ПС [15]. Критерием правильности в данном случае является мнение группы экспертов и специалистов по оценке соответствия подъемных сооружений требованиям промышленной безопасности. В таблице 2 представлены уровни активации каждого из трех нейронов выходного слоя. Уровень активации нейрона выходного слоя отражает степень уверенности ИНС в определении технического состояния ПС [16]. Сумма активаций трех нейронов составляет единицу. Нейрон с наивысшим уровнем активации считается «победившим», что определяет окончательное техническое состояние ПС, определенное ИНС [17].

Таблица 2

Уровни активации нейронов выходного слоя (x_1 – x_8)

Выборка (тест)	Состояние ПС – целевая	Состояние ПС – выход	Состояние ПС – 1 (доверительный уровень)	Состояние ПС – 2 (доверительный уровень)	Состояние ПС – 3 (доверительный уровень)
1	2	2	0,22	0,52	0,26
2	2	2	0,42	0,54	0,04
3	1	1	0,67	0,21	0,12
4	2	2	0,11	0,73	0,16
5	3	3	0,07	0,23	0,70
6	2	2	0,14	0,53	0,33
7	1	1	0,65	0,21	0,14
8	2	2	0,41	0,53	0,06
9	1	1	0,80	0,11	0,09
10	1	1	0,61	0,28	0,11

В тестовых выборках целевое значение технического состояния было заранее определено экспертным методом. ИНС правильно определили техническое состояние ПС [18] в каждой тестовой выборке. При этом среднее значение доверительного уровня определения технического состояния ПС составило 0,628.

Далее в таблице 3 представлены 30 обучающих выборок по девяти нейронам, соответствующим браковочным показателям металлоконструкций ПС (x_9 – x_{17} из таблицы 1). При обучении нейронной сети эти выборки были добавлены к выборкам из таблицы 1. То есть сеть была переобучена с включением дополнительных параметров.

Таблица 3

Обучающие выборки (представлены частично) ИНС (x_9 – x_{17})

№ п/п	x_9	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}	x_{16}	x_{17}	y
1	18	0	0	0	29	0	20	0	0	1
2	0	0	14	5	20	33	0	14	5	2
3	0	0	16	0	0	0	0	26	0	2
4	0	14	16	0	7	0	13	16	0	1
5	0	0	35	49	0	0	0	35	49	3
6	0	0	0	32	0	0	0	0	32	1
7	12	0	0	0	0	16	0	0	0	2
8	0	5	0	34	0	12	23	0	34	2
9	0	0	4	35	0	0	8	4	35	1
10	52	0	57	15	60	0	24	57	15	3
...	...	...	...	...	...	...	...	...	...	...
30	0	0	0	55	0	12	0	0	55	2

Далее вновь обученная ИНС была проверена на тестовых выборках. Однако во входной слой тестовых выборок были также включены дополнительные параметры, как представлено на рис. 2. Доверительные уровни оценки технического состояния ПС занесены в таблицу 4.

Таблица 4

Уровни активации нейронов выходного слоя ИНС (x_9 – x_{17})

Выборка (тест)	Состояние ПС – Целевая	Состояние ПС – Выход	Состояние ПС – 1 (доверительный уровень)	Состояние ПС – 2 (доверительный уровень)	Состояние ПС – 3 (доверительный уровень)
1	2	2	0,18	0,58	0,24
2	2	2	0,33	0,64	0,03
3	1	1	0,69	0,21	0,1
4	2	2	0,1	0,72	0,18
5	3	3	0,06	0,23	0,71

6	3	3	0,09	0,3	0,61
7	1	1	0,65	0,21	0,14
8	2	2	0,41	0,53	0,06
9	1	1	0,86	0,10	0,04
10	2	2	0,37	0,59	0,04

ИНС, в которую были добавлены 9 нейронов, отвечающих за дефекты несущих металлоконструкций ПС, также корректно оценила техническое состояние в каждой из тестовых выборок, при этом доверительный уровень повысился с 0,628 до 0,658.

Для проверки работы ИНС, модель которой представлена на рис. 3, было подготовлено еще 30 обучающих выборок (таблица 5). Данные выборки включали браковочные показатели болтовых и заклепочных элементов ПС.

Таблица 5

Обучающие выборки (представлены частично) ИНС ($x_{18} - x_{29}$)

№ п/п	x_{18}	x_{19}	x_{20}	x_{21}	x_{22}	x_{23}	x_{24}	x_{25}	x_{26}	x_{27}	x_{28}	x_{29}	y
1	0	5	0	26	0	0	10	0	0	0	0	0	1
2	0	0	0	0	0	0	0	24	0	6	5	0	2
3	0	0	50	0	0	0	0	0	0	0	0	0	2
4	48	0	0	0	73	0	0	0	0	0	23	0	2
5	57	0	0	0	0	0	0	0	0	0	0	22	3
6	0	14	17	0	0	0	39	0	10	28	0	0	1
7	0	0	23	0	0	0	0	0	0	0	0	0	2
8	0	0	17	0	0	11	0	0	84	0	0	11	3
9	0	32	2	0	1	0	6	0	0	0	14	0	1
10	92	0	0	0	0	33	19	0	0	21	0	13	3
...	...	...	...	...	...	...	...	...	...	...	...	...	...
30	0	0	5	0	0	0	15	0	0	10	5	0	2

Доверительные уровни оценки технического состояния ПС занесены в таблицу 6.

Таблица 6

Уровни активации нейронов выходного слоя ИНС ($x_{18} - x_{29}$)

Выборка (тест)	Состояние ПС — Целевая	Состояние ПС — Выход	Состояние ПС-1 (доверительный уровень)	Состояние ПС-2 (доверительный уровень)	Состояние ПС-3 (доверительный уровень)
1	3	3	0,11	0,30	0,59
2	2	2	0,26	0,72	0,02
3	1	1	0,65	0,26	0,09
4	2	2	0,10	0,78	0,12
5	3	3	0,06	0,23	0,71
6	3	3	0,02	0,26	0,72
7	1	1	0,63	0,24	0,13
8	2	2	0,39	0,56	0,05
9	1	1	0,90	0,09	0,01
10	1	1	0,79	0,11	0,10

В результате применения искусственной нейронной сети, представленной на рис. 3, было установлено, что модель корректно определяет техническое состояние подъёмных сооружений в 100 % случаев. Среднее значение доверительных уровней оценки технического состояния ПС увеличилось с 0,628 до 0,705 для текущей модели. Это свидетельствует о повышении точности и надёжности прогнозов, что является важным показателем эффективности разработанной системы [19].

Выходной слой обученных нейронных сетей использует функцию активации softmax. Для каждого из трёх классов k степень уверенности модели вычисляется как: $p_{_k} = \exp(z_{_k}) / \sum_{j=1..3} \exp(z_{_j})$, где: $p_{_k}$ — степень уверенности (нормированная вероятность) того, что состояние относится к классу k ; $\exp(z_{_k})$ — экспонента от $z_{_k}$; $z_{_k}$ —

взвешенная сумма сигналов, поступающих от последнего скрытого слоя на выходной нейрон k : $\sum_{j=1..3} \exp(z_{_j_k})$ — сумма экспонент по всем трём классам (нормировочный коэффициент). Значения $p_{_k}$ для тестовых примеров приведены в таблицах 3, 5 и 7. Например, для тестового примера №5 (модель с 29 входами, таблица 7) значения $z_{_k}$ до нормализации составили: $z_{₁} = 0,82$ (класс 1), $z_{₂} = 1,15$ (класс 2), $z_{₃} = 1,95$ (класс 3). После применения softmax получены степени уверенности $p_{₁} = 0,06$, $p_{₂} = 0,23$, $p_{₃} = 0,71$. Таким образом, между комбинацией браковочных показателей на входе и уровнями активации выходных нейронов существует количественная связь, задаваемая архитектурой сети и её обученными весами. Для данного примера наибольшая активация ($p_{₃} = 0,70$) соответствует классу 3, что совпадает с экспертным заключением. Выявлено влияние количества входных параметров нейронной сети, включая дефекты канатно-блочной и тормозной систем, ходовой части, металлоконструкций и болтовых соединений на уровне достоверности определения технического состояния подъемных сооружений. Установлена численная зависимость между уровнями активации нейронов искусственной нейронной сети и техническим состоянием подъемных сооружений на основе комбинаций браковочных показателей, выраженных в процентах от допустимой степени повреждения. Результатом функционирования искусственных нейронных сетей является корректное определение технического состояния подъемных сооружений, подтвержденное специалистами в области промышленной безопасности [20].

Обсуждение. Увеличение количества входных параметров с 8 до 29 сопровождается ростом уровня доверия классификации. Наибольший вклад в это повышение вносят параметры металлоконструкций (x_9 – x_{17}). Вероятно, это обусловлено физической природой дефектов данной группы. В отличие от локальных повреждений ходовой части или канатно-блочной системы, которые обычно устраняются при текущем ремонте, остаточные прогибы и деформации несущих металлоконструкций отражают системные изменения, снижающие общую несущую способность сооружения. Именно сочетание локального износа и системных деформаций служит маркером перехода из класса 1 в класс 2. Параметры болтовых и заклепочных соединений, обеспечивающие дополнительный, хотя и меньший прирост уровня доверия, позволяют сети выявлять случаи ослабления стыков, характерные для предельного состояния (класс 3). Сравнение с литературными данными показывает, что полученные результаты согласуются с исследованиями по применению машинного обучения в диагностике технических систем. В них указано, что рост числа учитываемых параметров повышает точность прогнозов. Однако, в отличие от подходов, моделирующих отдельные физические процессы, предложенная модель оценивает интегральное состояние на основе совокупности браковочных показателей. Это делает её применимой при ограниченной информации о фактических режимах эксплуатации, что составляет её преимущество перед методами, требующими детальных данных о нагружении [21]. Помимо физической природы дефектов, на результаты модели повлияли корреляционные связи между входными параметрами. Остаточный прогиб пролётного строения (x_9) коррелирует с деформацией полки уголка (x_{16}), поскольку оба параметра отражают общее снижение жёсткости металлоконструкции. Аналогично износ поверхности реборды ходового колеса (x_1) и выработка поверхности катания (x_2) часто проявляются совместно. Подобные корреляции не являются недостатком метода, поскольку нейронные сети устойчивы к мультиколлинеарности — они способны перераспределять веса между коррелированными признаками без потери предсказательной способности. Однако наличие корреляций может приводить к завышенной оценке значимости группы взаимосвязанных признаков. Добавление параметров из разных групп вносит преимущественно новую, некоррелированную информацию, что объясняет повышение уверенности модели. Практическими результатами исследования являются разработка и обучение трёх ИНС с различным числом входных нейронов: первая ИНС содержит 8 входных нейронов и демонстрирует тестовую точность 100 % при объёме тестовой выборки 10 примеров и средней доверительной вероятности 0,628. Основное ограничение исследования — небольшой объём доступных экспертных данных (30 выборки). При таком объёме утверждение о 100 % точности на тестовой выборке не может рассматриваться как статистически надёжное. Результаты кросс-валидации (средняя точность 0,89, стандартное отклонение 0,07) дают более реалистичную оценку. Таким образом, представленные выводы носят предварительный характер. Повышение средней степени уверенности модели с 0,628 (8 входов) до 0,658 (17 входов), а затем до 0,705 (29 входов) обусловлено следующими факторами. Во-первых, дефекты металлоконструкций (остаточные прогибы, деформации стержней, местные вмятины) и дефекты болтовых и заклепочных соединений (ослабление натяжения, коррозия, трещины) содержат информацию, частично независимую от дефектов ходовой части и канатно-блочной системы. Это позволяет нейронной сети выявлять такие комбинации, при которых, например, незначительный износ ходовых колёс (менее 30 % от браковочного значения) в сочетании с заметным остаточным прогибом металлоконструкции (более 50 % от предельного значения) может свидетельствовать о необходимости сокращения межремонтного срока (класс 2), тогда как по отдельности каждый из этих дефектов мог бы быть отнесён к работоспособному состоянию (класс 1). Во-вторых, увеличение

размерности входного пространства при фиксированном объёме обучающей выборки (30 примеров) обычно повышает риск переобучения, однако в данном случае рост уверенности свидетельствует о том, что добавляемые параметры действительно содержат релевантную для классификации информацию, а не являются шумом [22]. В-третьих, браковочные показатели металлоконструкций и соединений нормированы в процентах от предельных значений, что позволяет сети с сопоставимой значимостью учитывать различные типы дефектов независимо от их физической природы.

Заключение. В ходе исследования разработаны и апробированы три модели искусственных нейронных сетей для комплексной оценки технического состояния подъемных сооружений по браковочным показателям, установленным федеральными нормами и правилами в области промышленной безопасности. По результатам исследования выполнены следующие задачи:

1. Систематизированы 29 браковочных показателей подъемных сооружений в соответствии с ФНП⁹. Показатели структурированы по трём группам: дефекты ходовой части, тормозной и канатно-блочной систем (x_1 – x_8); несущих металлоконструкций (x_9 – x_{17}); болтовых и заклепочных соединений (x_{18} – x_{29}). На их основе определены структуры входных данных для нейросетевых моделей.

2. Разработаны и обучены три модели многослойного персептрона с одинаковой архитектурой скрытых слоёв (три слоя по восемь нейронов) и входными слоями размерности 8, 17 и 29 нейронов соответственно. Все модели имеют выходной слой из трёх нейронов, соответствующих трём классам технического состояния.

3. Сформированы обучающие (30 примеров) и тестовые (10 примеров) выборки на основе 40 экспертных наборов дефектов, классифицированных тремя независимыми экспертами.

4. Проведено обучение и тестирование разработанных моделей. Все три модели показали 100 % точность классификации на тестовой выборке.

5. Установлено, что увеличение числа входных параметров повышает доверительный уровень классификации, что свидетельствует о значимости учёта комбинаций дефектов различных элементов подъемного сооружения.

Результаты носят предварительный характер и демонстрируют принципиальную возможность использования нейросетевого подхода для комплексной оценки ПС. Для внедрения в практическую деятельность необходимо расширение обучающей выборки до нескольких сотен реальных экспертных заключений и проведение валидации на независимом наборе данных.

Список литературы / References

1. Tao Li, Wei Wu, Xiufeng Li, Yongquan Li, Xueru Gong, Shuai Zhang, et al. A Hybrid Approach Combining Scenario Deduction and Type-2 Fuzzy Set-Based Bayesian Network for Failure Risk Assessment in Solar Tower Power Plants. *Sustainability*. 2025;17(11):4774. <https://doi.org/10.3390/su17114774>

2. Xing Pan, Zekun Wu. Performance Shaping Factors in the Human Error Probability Modification of Human Reliability. *International Journal of Occupational Safety and Ergonomics*. 2020;26(3):538–550. <https://doi.org/10.1080/10803548.2018.1498655>

3. Antipas IR. Modeling of Dynamic Loads Affecting a Bridge Crane during Start-Up. *Advanced Engineering Research (Rostov-on-Don)*. 2024;24(2):190–197. <https://doi.org/10.23947/2687-1653-2024-24-2-190-197>

4. Sagnak M, Kazancoglu Y, Ozen Y, Garza-Reyes JA. Decision-Making for Risk Evaluation: Integration of Prospect Theory with Failure modes and effects analysis (FMEA). *International Journal of Quality & Reliability Management*. 2020;37(6–7):939–956. <https://doi.org/10.1108/IJQRM-01-2020-0013>

5. Короткий А.А., Панфилов А.В., Хван Р.В., Юсупов А.Р. Интегральный метод оценки дефектов на работоспособность стального каната с использованием искусственных нейронных сетей. *Транспортное, горное и строительное машиностроение: наука и производство*. 2023;18:73–79. <https://doi.org/10.26160/2658-3305-2023-18-73-79>

Korotkiy AA, Panfilov AV, Khvan RV, Yusupov AR. Integral Method of Assessing Defects on the Operability of Steel Rope Using Artificial Neural Networks. *Transport, Mining and Construction Engineering: Science and Production*. 2023;18:73–79. <https://doi.org/10.26160/2658-3305-2023-18-73-79>

6. Аблязов Э.К., Аблязов К.А. Оценка технического состояния портового подъемно-транспортного оборудования (ПТО) с использованием нечеткой логики. *Морские интеллектуальные технологии*. 2024;2(1):242–251. <https://doi.org/10.37220/mit.2024.64.2.027>

Ablyazov EK, Ablyazov KA. Assessment of the Technical Condition of Port Lifting and Transport Equipment (LTE) Using Fuzzy Logic. *Marine Intellectual Technologies*. 2024;2(1):242–251. <https://doi.org/10.37220/mit.2024.64.2.027>

7. Долгов О.С., Сафоклов Б.Б. Проектирование модели технического обслуживания и ремонта воздушных судов с использованием искусственных нейронных сетей. *Вестник Московского авиационного института*. 2022;29(1):19–26. <https://doi.org/10.34759/vst-2022-1-19-26>

⁹ Там же. С. 84–87

Dolgov OS, Safoklov BB. Developing Maintenance and Refurbishment Model of Aerial Vehicles with Artificial Neural Network Application. *Aerospace MAI Journal*. 2022;29(1):19–26. <https://doi.org/10.34759/vst-2022-1-19-26>

8. 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 G. Development of an Integrated Algorithm for Processing GTE Diagnostic Parameters Using Multilayer Neural Networks. *Testing. Diagnostics*. 2025;(7):41–54. <https://doi.org/10.14489/td.2025.07.pp.041-054>

9. 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. <https://doi.org/10.17816/0321-4443-106169>

10. Хазиев М.Л. Диагностика надежности гидравлического привода с применением нейронных сетей. *Социально-экономические и технические системы: исследование, проектирование, оптимизация*. 2025;(1):114–122. <https://seats.elpub.ru/jour/article/view/179> (дата обращения: 08.09.2025).

Khaziev ML. Diagnostics of Hydraulic Drive Reliability Using Neural Networks. *Social-Economic and Technical Systems: Research, Design and Optimization*. 2025;(1):114–122. <https://seats.elpub.ru/jour/article/view/179> (accessed: 08.09.2025).

11. 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*. 2025;(15):89–92. <https://doi.org/10.26160/2541-8637-2025-15-89-92>

12. Egelsky VV, Nikolaev NN, Egelskaya EV, Korotkiy AA. Influence of the Competencies of Lifting Crane Specialists on the Probability of Emergencies. *Safety of Technogenic and Natural Systems*. 2023;(2):70–79. <https://doi.org/10.23947/2541-9129-2023-7-2-70-79>

13. Khvan RV. Use of Artificial Neural Networks for Solving the Problem of Residual Resource Estimation of Hoisting Cranes. *E3S Web of Conferences*. 2024;515(11):04015. <https://doi.org/10.1051/e3sconf/202451504015>

14. Dennig D, Bureick J, Link J, Diener D, Hesse C, Neumann I. Comprehensive and Highly Accurate Measurements of Crane Runways, Profiles and Fastenings. *Sensors*. 2017;17(5):1118 <https://doi.org/10.3390/s17051118>

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

16. Tong Yang, Ning Sun, He Chen, Yongchun Fang. Motion Trajectory-Based Transportation Control for 3-D Boom Cranes: Analysis, Design, and Experiments. *IEEE Transactions on Industrial Electronics*. 2019;66(5):3636–3646. <https://doi.org/10.1109/tie.2018.2853604>

17. Panasiuk JA, Adamus A. A Study on Elements of Machine Vision and Machine Learning in Industrial Vision Systems. *Problems of Mechatronics Armament Aviation Safety Engineering*. 2024;15(3):87–106. <https://doi.org/10.5604/01.3001.0054.7513>

18. Egelsky VV, Nikolaev NN, Egelskaya EV, Korotkiy AA. Use of Artificial Intelligence to Monitor the Reliability of Removable Load-Handling Devices. *Safety of Technogenic and Natural Systems*. 2024;(2):57–67. <https://doi.org/10.23947/2541-9129-2024-8-2-57-67>

19. Pullin R, Holford KM, Lark RJ, Eaton MJ. Acoustic Emission Monitoring of Bridge Structures in the Field and Laboratory. *Journal of Acoustic Emission*. 2008;26:172–181. URL: <https://www.ndt.net/article/ewgae2008/papers/136.pdf> (accessed: 08.10.2025)

20. 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. <https://doi.org/10.24000/0409-2961-2025-6-7-13>

21. Molokov KA, Novikov VV, Dabalez M. Evaluation of the Occurrence of Initial Failures from Stress Concentrators in Welded Joints and Structural Elements. *Advanced Engineering Research (Rostov-on-Don)*. 2023;23(1):41–54. <https://doi.org/10.23947/2687-1653-2023-23-1-41-54>

22. Sobhanifard F. Optimization of Bayesian Neural Networks Using Hybrid PSO and Fuzzy Logic Approach for Time Series Forecasting. *Discover Artificial Intelligence*. 2025;5(132). <https://doi.org/10.1007/s44163-025-00322-9>

Об авторах:

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

Анатолий Аркадьевич Короткий, доктор технических наук, профессор, заведующий кафедрой «Эксплуатация транспортных систем и логистика» Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [SPIN-код](#), [ORCID](#), [ScopusID](#), [ResearcherID](#), korotaa@gmail.com

Заявленный вклад авторов:

Р.В. Хван: разработка методологии, административное руководство исследовательским проектом, проведение исследования, написание рукописи, визуализация, формальный анализ, валидация результатов, курирование данных, написание черновика рукописи.

А.А. Короткий: разработка концепции, научное руководство.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Все авторы прочитали и одобрили окончательный вариант рукописи.

Декларация ИИ: авторы заявляют, что при подготовке рукописи «Контроль технического состояния подъемных сооружений и оборудования с использованием искусственных нейронных систем» не использовались технологии генеративного искусственного интеллекта (ИИ), ИИ не является соавтором публикации: авторство присвоено только физическим лицам, внёсшим существенный интеллектуальный вклад в исследование.

About the Authors:

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

Anatoly A. Korotky, Dr.Sci. (Eng.), Professor, Head of the Department of Transport Systems Operation and Logistics, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [SPIN-code](#), [ORCID](#), [ScopusID](#), [ResearcherID](#), korotaa@gmail.com

Claimed Contributorship:

RV Khvan: methodology, project administration, investigation, visualization, formal analysis, validation, data curation, writing – original draft preparation, writing – review & editing.

AA Korotky: conceptualization, supervision.

Conflict of Interest Statement: the authors declare no conflict of interest.

All authors have read and approved the final version of manuscript.

AI Declaration: The authors declare that generative artificial intelligence (AI) technologies were not used in the preparation of the manuscript “Technical Condition Monitoring of Lifting Structures and Equipment Using Artificial Neural System” and that AI is not a co-author of the publication: authorship is assigned only to natural persons who have made a substantial intellectual contribution to the research.

Поступила в редакцию / Received 04.05.2026

Поступила после рецензирования / Reviewed 21.05.2026

Принята к публикации / Accepted 09.06.2026