

Оригинальная статья

УДК 004.032.26:66.017

DOI: 10.57070/2304-4497-2025-2(52)-85-91

**РАСПОЗНАВАНИЕ ДЕФЕКТОВ НА ПОВЕРХНОСТИ МЕТАЛЛА
С ИСПОЛЬЗОВАНИЕМ МЕТОДА МАШИННОГО ОБУЧЕНИЯ**

© 2025 г. В. А. Кузнецова¹, А. В. Маркидонов^{1, 2}

¹Сибирский государственный индустриальный университет (Россия, 654007, Кемеровская обл. – Кузбасс, Новокузнецк, ул. Кирова, 42)

²Кузбасский гуманитарно-педагогический институт Кемеровского государственного университета (Россия, 654027, Кемеровская обл. – Кузбасс, Новокузнецк, ул. Циолковского, 23)

Аннотация. В связи с увеличением требований к качеству продукции в металлургической и машиностроительной промышленности возникает необходимость внедрения современных технологий для автоматического контроля качества. Поверхностные дефекты металлических изделий (трещины, царапины и включения) напрямую влияют на надежность и долговечность продукции. Традиционные методы визуального и оптического контроля требуют значительных временных и трудовых затрат, подвержены влиянию человеческого фактора и не всегда обеспечивают достаточную точность. В рамках исследования был проведен обзор современных публикаций, в которых рассматриваются подходы к автоматической классификации дефектов, а также обсуждаются возможности и ограничения архитектур нейронных сетей. Анализ источников позволил выявить тенденции развития в рассматриваемой области и обосновать выбор архитектуры модели. Предлагается подход к распознаванию дефектов на изображениях металлических поверхностей с использованием сверточных нейронных сетей. Разработана архитектура модели, включающая три сверточных слоя и полносвязные нейроны, оптимизированные с использованием функции активации ReLU, слоя Dropout и выходного слоя Softmax. Для обучения модели использовали открытый набор данных, содержащий 1800 черно-белых изображений с шестью различными типами дефектов. Точность классификации составила 95,83 %, а значение функции потерь – 0,0862. При проверке на тестовой выборке модель верно распознала 70 из 72 изображений. Проведенное исследование подтверждает эффективность нейронных сетей в задаче обнаружения визуальных дефектов. Представленная модель может быть использована в системах автоматизированного контроля качества и дополнительно адаптирована под различные промышленные условия. В дальнейшем планируется оптимизация архитектуры модели для повышения устойчивости к шумам и вариативности данных.

Ключевые слова: машинное обучение, дефекты металлических поверхностей, сверточная нейронная сеть, классификация изображений

Для цитирования: Кузнецова В.А., Маркидонов А.В. Распознавание дефектов на поверхности металла с использованием метода машинного обучения. *Вестник Сибирского государственного индустриального университета*. 2025;2(52):85–91. [http://doi.org/10.57070/2304-4497-2025-2\(52\)-85-91](http://doi.org/10.57070/2304-4497-2025-2(52)-85-91)

Original article

RECOGNITION OF DEFECTS ON THE METAL SURFACE USING MACHINE LEARNING

© 2025 V. A. Kuznetsova¹, A. V. Markidonov^{1, 2}

¹Siberian State Industrial University (42 Kirova Str., Novokuznetsk, Kemerovo Region – Kuzbass, 654007, Russian Federation)

²Kuzbass Humanitarian Pedagogical Institute of Kemerovo State University (23 Tsiolkovsky Str., Novokuznetsk, Kemerovo Region – Kuzbass, 654027, Russian Federation)

Abstract. Due to the increase in product quality requirements in the metallurgical and machine building industries, it is necessary to introduce modern technologies for automatic quality control. Surface defects of metal products (cracks, scratches and inclusions) directly affect the reliability and durability of products. Traditional methods of

visual and optical control require significant time and labor costs, are subject to the influence of the human factor and do not always provide sufficient accuracy. Within the framework of the study, a review of modern publications was conducted, which consider approaches to automatic defect classification, as well as discuss the possibilities and limitations of neural network architectures. The analysis of the sources made it possible to identify development trends in the field under consideration and justify the choice of the model architecture. An approach to the detection of defects in images of metal surfaces using convolutional neural networks is proposed. The architecture of the model has been developed, which includes three convolutional layers and fully connected neurons optimized using the ReLU activation function, the Dropout layer and the Softmax output layer. To train the model, we used an open dataset containing 1800 black and white images with six different types of defects. The classification accuracy was 95.83 %, and the value of the loss function was 0.0862. When tested on a test sample, the model correctly recognized 70 out of 72 images. The conducted research confirms the effectiveness of neural networks in the task of detecting visual defects. The presented model can be used in automated quality control systems and additionally adapted to various industrial conditions. In the future, optimization of the model architecture is planned to increase noise tolerance and data variability.

Keywords: machine learning, defects of metal surfaces, convolutional neural network, image classification

For citation: Kuznetsova V.A., Markidonov A.V. Recognition of defects on the metal surface using machine learning. *Bulletin of the Siberian State Industrial University*. 2025;2(52):85–91. [http://doi.org/10.57070/2304-4497-2025-2\(52\)-85-91](http://doi.org/10.57070/2304-4497-2025-2(52)-85-91)

Введение

Обеспечение высокого качества металлических изделий на этапе производства требует своевременного и точного выявления дефектов поверхности, так как их наличие может существенно повлиять не только на внешний вид продукции, но и на ее прочность и надежность [1]. Поверхностные повреждения снижают безопасность использования изделий, в связи с этим контроль качества поверхности становится неотъемлемым этапом технологического процесса [2].

Традиционный метод ручного контроля отнимает много времени, а человеческая ошибка неизбежна, когда требуется проверка большого количества изделий [3]. В целях повышения эффективности контроля все чаще применяются автоматизированные системы оптического анализа [4]. Однако классические алгоритмы обработки изображений не всегда позволяют достоверно выявлять сложные или слабовыраженные дефекты на металлических поверхностях [5], что обуславливает необходимость внедрения более прогрессивных подходов (машинного зрения). Методы машинного обучения демонстрируют более высокую точность по сравнению с ручным контролем [6], способствуют снижению затрат, связанных с устранением последствий дефектов, а также позволяют сократить участие человека в процессе контроля [7].

Необходимость совершенствования систем контроля актуальна не только для металлургии и машиностроения, но и для других отраслей, например, при диагностике состояния железнодорожных путей. В настоящее время широко применяются методы ультразвукового и магнитного контроля рельсов, однако такие технологии требуют значительных временных и финансовых

ресурсов [8]. В работе [8] представлен подход, позволяющий автоматически проводить классификацию текущего изображения на основе заранее обученных образцов. Система продемонстрировала высокую эффективность, достигнув точности 94,9 % при сравнении с результатами ручной классификации изображений.

В последние годы все более популярным становится аддитивное производство, однако долговечность и надежность изготавливаемых компонентов зависят от своевременного обнаружения дефектов [9]. В этих условиях методы машинного обучения (нейронные сети) приобретают все большее значение как инструмент для прогнозирования свойств материалов и автоматического обнаружения дефектов благодаря их способности обрабатывать большие объемы данных и выявлять сложные зависимости между параметрами [10].

Согласно аналитическим данным, уже к 2023 г. технологии, основанные на нейросетевых моделях, были внедрены на более чем 50 % российских промышленных предприятий [11], что свидетельствует о высокой степени востребованности рассматриваемых подходов. Особенно эффективными оказались нейронные сети, обученные на изображениях поверхностей и способные распознавать различные формы повреждений. Например, в работе [12] описано использование глубоких сверточных нейронных сетей для обнаружения и классификации дефектов поверхности стали. Этот метод продемонстрировал 98,2 % точности, а среднее время выполнения оказалось быстрее, чем у других моделей.

Ранее научные исследования были ориентированы преимущественно на двумерные изде-




Рис. 1. Примеры изображений из исходного набора данных
Fig. 1. Example images from the original dataset

лия из листового металла, однако в последние годы наблюдается растущий интерес к анализу объектов с трехмерной формой. Например, в работе [13] был сформирован набор данных, полученный путем применения геометрических преобразований, отражающих параметры конструкции оборудования, используемого для визуального контроля дефектов на металлических поверхностях. Проведенные экспериментальные испытания показали, что разработанный алгоритм демонстрирует высокие показатели эффективности, приближенные к оптимальным.

Интеграция алгоритмов машинного обучения в процессы технической диагностики металлических изделий способна существенно повысить качество производимой продукции, снизить влияние человеческого фактора и повысить конкурентоспособность предприятий. Современные исследования подтверждают, что корректно построенные модели машинного обучения способны достигать производительности, сопоставимой с глубокими нейронными архитектурами [14]. Однако успешное применение подобных подходов требует внимательного подбора и тонкой настройки моделей с учетом специфики решаемой задачи и характеристик доступных данных [15].

Целью настоящей работы является разработка программной реализации модели на основе сверточных нейронных сетей, предназначенной для распознавания и классификации дефектов на поверхности металла.

Методы и принципы исследования

В ходе разработки программного обеспечения были использованы среда программирования Python и облачная платформа Google Colab, предоставляющая ресурсы для выполнения вычислений и взаимодействия с данными. Обучение и тестирование модели происходило с помощью библиотеки Keras. В качестве исходных данных применялся набор изображений, полученный с платформы Kaggle [16]. Этот датасет охватывает шесть категорий характерных дефектов поверхности металлических изделий, каждая из которых оказывает значительное влияние на прочность и качество металлической продукции.

База данных включает в себя 1800 черно-белых изображений по 300 изображений на каждый тип дефекта (включение, вкатанная окалина, точечная коррозия, царапины, пятна, трещины) (рис. 1).

Для корректной оценки качества обучения исходный набор данных был разделен на три части: обучающую, валидационную и тестовую выборки. Обучающая выборка содержит по 276 изображений каждого класса, что позволяет модели выявить ключевые закономерности и особенности, характерные для каждого типа дефекта. Валидационная выборка, включающая по 12 изображений на класс, применяется для настройки гиперпараметров модели и предотв-




Рис. 2. Результаты обучения и тестирования модели
Fig. 2. Results of training and testing the model

ращения переобучения. Оценка итоговой эффективности классификатора проводится на тестовой выборке, также включающей по 12 изображений для каждой категории дефектов.

Разработанная архитектура нейронной сети для задачи классификации дефектов на металлических поверхностях основана на комбинации сверточных и полносвязных слоев, адаптированных для анализа изображений [17]. Модель состоит из трех сверточных слоев, содержащих 32, 64 и 128 фильтров размером 2×2 , в каждом из блоков используется функция активации ReLU [18]. Эти слои отвечают за извлечение и иерархическое представление признаков, содержащихся во входных изображениях.

Для снижения пространственного разрешения признаков карт и уменьшения вычислительной сложности, после каждого сверточного слоя применяется слой подвыборки (Max Pooling) с размером окна 2×2 , что также способствует снижению вероятности переобучения. Полученные двумерные карты признаков подвергаются операции выравнивания (Flatten), преобразующей их в одномерный вектор, пригодный для обработки полносвязными слоями [19].

В полносвязной части архитектуры используется Dense-слой с 256 нейронами и функцией активации ReLU, которые обеспечивают обучение сложных представлений признаков. Для уменьшения риска переобучения добавлен слой Dropout с коэффициентом 0,2, временно деактивирующий 20 % нейронов во время обучения [20]. Последний полносвязный слой содержит шесть нейронов с функцией активации Softmax, что позволяет модели формировать вероятностное распределение по шести классам выявляемых дефектов.

Обучение модели осуществляли с использованием оптимизатора Adam, который характеризу-

ется высокой эффективностью и способностью к адаптивной настройке параметров в процессе обучения. Полный цикл обучения охватывал 30 эпох, что обеспечило достаточную сходимость модели для решения задачи классификации.

Результаты и обсуждение

По результатам обучения разработанной модели были получены следующие ключевые показатели: значение функции потерь составило 0,0862, достигнутая точность классификации – 95,83 %. Эти значения свидетельствуют о высокой способности модели к обобщению. Высокая точность указывает на то, что модель успешно распознает и классифицирует большинство входных изображений, включая те, которые не использовали в процессе обучения.

Сопоставление показателей точности на обучающей и тестовой выборках позволяет утверждать, что модель не склонна к переобучению, она извлекает устойчивые паттерны, характерные для различных категорий дефектов. Это подтверждает ее способность к переносу знаний на новые примеры, что является важным требованием при решении задач промышленной диагностики.

На рис. 2 представлены графики изменения точности и значения функции потерь в зависимости от номера эпохи обучения. Анализ этих зависимостей позволяет визуально оценить динамику процесса обучения и зафиксировать момент сходимости модели.

Более детальный анализ результатов на тестовой выборке показал, что из 72 изображений модель правильно классифицировала 70, допустив лишь две ошибки. Это соответствует уровню точности 97 % для конкретной тестовой выборки и дополнительно подтверждает стабильность работы модели при распознавании различных типов дефектов.

Полученные результаты демонстрируют высокую эффективность построенной архитектуры. В рамках дальнейших исследований планируется доработка архитектуры с целью снижения значения функции потерь и повышения общей точности модели.

Выводы

Разработана и реализована модель на основе сверточной нейронной сети для распознавания дефектов на поверхности металлических изделий. Проведенное обучение и последующее тестирование модели показали ее высокую эффективность: достигнута точность классификации 95,83 % при значении функции потерь 0,0862. При проверке на тестовой выборке из 72 изображений модель допустила лишь две ошибки, что соответствует точности 97 %. Эти показатели подчеркивают эффективность модели в рассматриваемой задаче, демонстрируя ее способность классифицировать изображения дефектов поверхности металла.

Результаты исследования свидетельствуют о целесообразности применения методов машинного обучения, в частности нейронных сетей, для решения задач визуального контроля качества в металлургической промышленности.

В дальнейшем планируется проведение оптимизации архитектуры модели, позволяющее эффективно адаптировать ее к условиям реального производственного процесса.

СПИСОК ЛИТЕРАТУРЫ

- Huang Y., Yu T., Wan K., Yuan J. Detection and classification of metal workpiece surface defects based on machine vision. *2021 IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA)*. 2021:983–987. <https://doi.org/10.1109/AEECA52519.2021.9574344>
- Bai J., Wu D., Shelley T., Schubel P., Twine D., Russell J., Zeng X., Zhang J. A comprehensive survey on machine learning driven material defect detection: challenges, solutions, and future prospects. *ACM Computing Surveys*. 2024. <https://doi.org/10.48550/arXiv.2406.07880>
- Zhou C., Lu Z., Lv Z. et al. Metal surface defect detection based on improved YOLOv5. *Scientific Reports*. 2023;13:20803. <https://doi.org/10.1038/s41598-023-47716-2>
- Chen S., Zhou F., Gao G., Ge X., Wang R. Unleashing the power of AI in detecting metal surface defects: an optimized YOLOv7-tiny model approach. *PeerJ. Computer science*. 2024;10:e1727. <https://doi.org/10.7717/peerj-cs.1727>
- Huang Y.C., Hung K.C., Lin J.C. Automated machine learning system for defect detection on cylindrical metal surfaces. *Sensors*. 2022;22(24):9783. <https://doi.org/10.3390/s22249783>
- Балеев И.А., Земцов А.Н., Зыбин М.И., Смирнов В.А. Распознавание дефектов на металлических сплавах с помощью алгоритмов компьютерного зрения OpenCV. *Инженерный вестник Дона*. 2021;3(75):78–87.
- Погадаева Е.Ю. Распознавание дефектов сварных соединений по фотоизображению для проведения визуального контроля. *Молодой ученый*. 2020;43(333):5–9.
- Румановский И.Г., Калинин Н. А., Никитин Н.А. Применение нейросетевых технологий для дефектоскопии железнодорожных путей. *Вестник Тихоокеанского государственного университета*. 2023; 4(71):25–40.
- Dean K. Argonne scientists use AI to detect hidden defects in stainless steel. *Nuclear News*, 2025. URL: <https://www.ans.org/news/article-6706/argonne-scientists-use-ai-to-detect-hidden-defects-in-stainless-steel>. (Дата обращения: 10.04.2025).
- Панова В.С., Кузнецова В.А., Панченко И.А. Применение нейронных сетей для прогнозирования свойств высокоэнтропийных сплавов. В кн.: *Ультрамелкозернистые и наноструктурные материалы: Сборник трудов открытой школы-конференции стран СНГ*. Уфимский университет науки и технологий. 2024:154.
- Искусственный интеллект в металлургии: как его используют для обнаружения дефектов. 2024. URL: <https://indpages.ru/prom/iskusstvennyj-intellekt-v-metallurgii-kak-ego-ispolzuyut-dlya-obnaruzheniya-defektov/> (Дата обращения: 10.04.2025).
- Wang S., Xia X., Ye L., Yang B. Automatic detection and classification of steel surface defect using deep convolutional neural networks. *Metals*. 2021;11(3):388. <https://doi.org/10.3390/met11030388>
- Suh S. Optimal surface defect detector design based on deep learning for 3D geometry. *Scientific Reports*. 2025;15:5527. <https://doi.org/10.1038/s41598-025-88112-2>
- Keshinro B. Image detection and classification: a machine learning approach. 2022. <http://dx.doi.org/10.2139/ssrn.4281011>
- Рыбаков К.М., Хамитов Р.М. Проблемы поверхностной дефектоскопии металлов с использованием машинного обучения и пути их решения. *International Journal of Advanced Studies*. 2024; 14(1):196–204.

- <https://doi.org/10.12731/2227-930X-2024-14-1-289>
16. Metal Surface Defects Dataset. Kaggle. URL: <https://www.kaggle.com/datasets/fantacher/neu-metal-surface-defects-data/data?select=NEU+Metal+Surface+Defects+Data> (Дата обращения: 25.03.2025).
 17. Lv Q., Zhang S., Wang Y. Deep Learning Model of Image Classification Using Machine Learning. *Advances in Multimedia*. 2022; 3351256. <https://doi.org/10.1155/2022/3351256>
 18. Pilyay A. I. Detection of defects in building materials using artificial intelligence systems. *Construction and Architecture*. 2023;11(1):20. <https://doi.org/10.29039/2308-0191-2022-11-1-20-20>
 19. Cherkasov N., Ivanov S., Ivanov M., Ulanov A. Detection of defects in welded butt joints based on laser scanning: neural networks approach. In: *International Ural conference on electrical power engineering (UralCon)*. 2023: 775–779. <https://doi.org/10.1109/UralCon59258.2023.10291060>
 20. Al-Mamun A.M., Hossain M.R., Sharmin M.M. Detection and classification of metal surface defects using lite convolutional neural network (LCNN). *Material Science & Engineering International Journal*. 2024; 8(3): 72–76. <https://doi.org/10.15406/mseij.2024.08.00239>
- ### REFERENCES
1. Huang Y., Yu T., Wan K., Yuan J. Detection and classification of metal workpiece surface defects based on machine vision. 2021 *IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA)*. 2021: 983–987. <https://doi.org/10.1109/AEECA52519.2021.9574344>
 2. Bai J., Wu D., Shelley T., Schubel P., Twine D., Russell J., Zeng X., Zhang J. A comprehensive survey on machine learning driven material defect detection: challenges, solutions, and future prospects. *ACM Computing Surveys*. 2024. <https://doi.org/10.48550/arXiv.2406.07880>
 3. Zhou C., Lu Z., Lv Z. et al. Metal surface defect detection based on improved YOLOv5. *Scientific Reports*. 2023;13:20803. <https://doi.org/10.1038/s41598-023-47716-2>
 4. Chen S., Zhou F., Gao G., Ge X., Wang R. Unleashing the power of AI in detecting metal surface defects: an optimized YOLOv7-tiny model approach. *PeerJ. Computer science*. 2024;10:e1727. <https://doi.org/10.7717/peerj-cs.1727>
 5. Huang Y.C., Hung K.C., Lin J.C. Automated machine learning system for defect detection on cylindrical metal surfaces. *Sensors*. 2022;22(24):9783. <https://doi.org/10.3390/s22249783>
 6. Baleev I.A., Zemtsov A.N., Zybin M.I., Smirnov V.A. Recognizing defects in metal alloys using OpenCV computer vision algorithms. *Inzhenernyi vestnik Dona*. 2021; 3 (75):78–87. (In Russ.).
 7. Pogadaeva E.Yu. Recognition of welded joint defects using a photographic image for visual inspection. *Molodoi ucheny*. 2020; 43(333):5–9. (In Russ.).
 8. Rumanovskii I.G., Kalinnikov N. A., Nikitin N.A. Application of neural network technologies for flaw detection of railway tracks. *Vestnik Tikhookeanskogo gosudarstvennogo universiteta*. 2023; 4(71):25–40. (In Russ.).
 9. Dean K. Argonne scientists use AI to detect hidden defects in stainless steel. *Nuclear News*, 2025. URL: <https://www.ans.org/news/article-6706/argonne-scientists-use-ai-to-detect-hidden-defects-in-stainless-steel>. (Дата обращения: 10.04.2025).
 10. Panova V.S., Kuznetsova V.A., Panchenko I.A. Application of neural networks for predicting the properties of high-entropy alloys. In: *Design Ultrafine-grained and nanostructured materials: Collection of works of the open school-conference of the CIS countries*. Ufa University of Science and Technology. 2024:154. (In Russ.).
 11. *Artificial Intelligence in Metallurgy: How It Is Used to Detect Defects*. 2024. (In Russ.). URL: <https://indpages.ru/prom/iskusstvennyj-intellekt-v-metallurgii-kak-ego-ispolzuyut-dlya-obnaruzheniya-defektov>.
 12. Wang S., Xia X., Ye L., Yang B. Automatic detection and classification of steel surface defect using deep convolutional neural networks. *Metals*. 2021;11(3):388. <https://doi.org/10.3390/met11030388>
 13. Suh S. Optimal surface defect detector design based on deep learning for 3D geometry. *Scientific Reports*. 2025;15:5527. <https://doi.org/10.1038/s41598-025-88112-2>
 14. Keshinro B. Image detection and classification: a machine learning approach. 2022. <http://dx.doi.org/10.2139/ssrn.4281011>
 15. Rybakov K.M., Khamitov R.M. Problems of surface flaw detection of metals using machine learning and ways to solve them. *International Journal of Advanced Studies*. 2024; 14(1):196–204. (In Russ.). <https://doi.org/10.12731/2227-930X-2024-14-1-289>
 16. Metal Surface Defects Dataset. Kaggle. URL: <https://www.kaggle.com/datasets/fantacher/neu>

-metal-surface-defects-data/data?select=NEU+Metal+Surface+Defects+Data (Дата обращения: 25.03.2025).

17. Lv Q., Zhang S., Wang Y. Deep Learning Model of Image Classification Using Machine Learning. *Advances in Multimedia*. 2022; 3351256.
<https://doi.org/10.1155/2022/3351256>
18. Pilyay A. I. Detection of defects in building materials using artificial intelligence systems. *Construction and Architecture*. 2023;11(1):20.
<https://doi.org/10.29039/2308-0191-2022-11-1-20-20>
19. Cherkasov N., Ivanov S., Ivanov M., Ulanov A. Detection of defects in welded butt joints based on laser scanning: neural networks approach. In: *International Ural conference on electrical power engineering (UralCon)*. 2023:775–779.
<https://doi.org/10.1109/UralCon59258.2023.10291060>
20. Al-Mamun A.M., Hossain M.R., Sharmin M.M. Detection and classification of metal surface defects using lite convolutional neural network (LCNN). *Material Science & Engineering International Journal*. 2024; 8(3): 72–76.
<https://doi.org/10.15406/mseij.2024.08.00239>

Сведения об авторах:

Валентина Анатольевна Кузнецова, обучающийся кафедры прикладной математики и информатики, Сибирский государственный индустриальный университет

E-mail: valyakuz28@mail.ru

ORCID: 0009-0007-5845-4928

SPIN-код: 1866-2000

Артём Владимирович Маркидонов, д.ф.-м.н., доцент, заведующий кафедрой информатики и вычислительной техники им. В.К. Буторина, Кузбасский гуманитарно-педагогический институт Кемеровского государственного университета; профессор кафедры прикладной математики и информатики, Сибирский государственный индустриальный университет

E-mail: markidonov_artem@mail.ru

ORCID: 0000-0002-4566-528X

SPIN-код: 3939-7328

Information about the authors:

Valentina A. Kuznetsova, student of the department of applied mathematics and computer science, Siberian State Industrial University

E-mail: valyakuz28@mail.ru

ORCID: 0009-0007-5845-4928

SPIN-код: 1866-2000

Artem V. Markidonov, Dr. Sci. (Phys.-math.), Associate Professor, head of the department of ivt after. V.K. Butorin, Kuzbass Humanitarian and Pedagogical Institute of Kemerovo State University, professor of the department of applied mathematics and computer science, Siberian State Industrial University

E-mail: markidonov_artem@mail.ru

ORCID: 0000-0002-4566-528X

SPIN-код: 3939-7328

Авторы заявляют об отсутствии конфликта интересов.

The authors declare that there is no conflict of interest.

Поступила в редакцию 18.04.2025

После доработки 28.05.2025

Принята к публикации 02.06.2025

Received 18.04.2025

Revised 28.05.2025

Accepted 02.06.2025