

Вестник Череповецкого государственного университета, 2026, № 1 (130), с. 75–84.  
Cherepovets State University Bulletin, 2026, no. 1 (130), pp. 75–84.

Научная статья  
УДК 004.932.4  
<https://doi.org/10.23859/1994-0637-2026-1-130-6>  
<https://elibrary.ru/offyx1>

### Метод оценки качества супер-разрешения орторектифицированных снимков крон деревьев

Иван Юрьевич Шаршов<sup>1✉</sup>, Владимир Валерьевич Березовский<sup>2</sup>  
Северный (Арктический) федеральный университет им. М. В. Ломоносова,  
Архангельск, Россия

<sup>1✉</sup>[sharshov-ivan@yandex.ru](mailto:sharshov-ivan@yandex.ru), <https://orcid.org/0000-0001-8001-9454>  
<sup>2</sup>[v.berezovsky@narfu.ru](mailto:v.berezovsky@narfu.ru), <https://orcid.org/0000-0003-1694-5896>

**Аннотация.** Исследование посвящено разработке метода оценки качества супер-разрешения орторектифицированных снимков крон деревьев с использованием сегментирующей нейросети U-Net в качестве критика. Подход позволяет сопоставлять структуры, выделенные на HR- и SR-изображениях, и количественно оценивать корректность реконструкции текстур. Метод демонстрирует согласованность с традиционными метриками и эффективен при анализе сложных объектов лесного покрова.

**Ключевые слова:** супер-разрешение, нейросеть, обработка спутниковых снимков

**Финансирование.** Статья подготовлена при финансовой поддержке РФФ в рамках гранта № 22-11-20025 «Создание и исследование элементов системы организации цепочки поставок древесного сырья с использованием технологии блокчейн и интеллектуального анализа данных»

**Для цитирования:** Шаршов И. Ю., Березовский В. В. Метод оценки качества супер-разрешения орторектифицированных снимков крон деревьев. *Вестник Череповецкого государственного университета*, 2026, № 1 (130), с. 75–84. <https://doi.org/10.23859/1994-0637-2026-1-130-6>; EDN: OFFYXI

### Method for assessing the quality of super-resolution of orthorectified tree-crown imagery

Ivan Iu. Sharshov<sup>1✉</sup>, Vladimir V. Berezovsky<sup>2</sup>  
Northern (Arctic) Federal University named after M. V. Lomonosov,  
Arkhangelsk, Russia

<sup>1✉</sup>[sharshov-ivan@yandex.ru](mailto:sharshov-ivan@yandex.ru), <https://orcid.org/0000-0001-8001-9454>  
<sup>2</sup>[v.berezovsky@narfu.ru](mailto:v.berezovsky@narfu.ru), <https://orcid.org/0000-0003-1694-5896>

**Abstract.** The study introduces a method for evaluating the quality of super-resolution applied to orthorectified images of tree crowns, using a U-Net segmentation model as an independent critic. The method enables quantitative comparison of structures extracted from HR and SR images and

© Шаршов И. Ю., Березовский В. В., 2026

demonstrates consistency with conventional metrics when analyzing complex textures of forest canopies.

**Keywords:** super-resolution, neural network, satellite image processing

**Funding.** This work was supported by the RSF under grant no. 22-11-20025 “Development and investigation of elements of a supply-chain management system for wood raw materials using block-chain technology and intelligent data analysis.”

**For citation:** Sharshov I. Iu., Berezovsky V. V. Method for assessing the quality of super-resolution of orthorectified tree-crown imagery. *Cherepovets State University Bulletin*, 2026, no. 1 (130), pp. 75–84. (In Russ.) <https://doi.org/10.23859/1994-0637-2026-1-130-6>; EDN: OFFYXI

## Введение

Качество изображения является визуальным атрибутом и фокусируется на оценке, основанной на восприятии человеком изображения. Методы оценки качества включают субъективные методы, основанные на оценочном суждении экспертной комиссии (подразумевается экспертная оценка в отсутствие объективных метрик при решении задачи), и объективные вычислительные методы.

Использование экспертной оценки приводит к более реалистичным результатам работы алгоритмов, так как чаще всего именно человек может четко отличить реалистичное изображение от сгенерированного. Однако такой метод является наиболее дорогостоящим и медленным относительно остальных.

Одним из самых распространенных методов оценки является вычисление пикового соотношения сигнала к шуму (PSNR). Оно определяется как максимальное значение сигнала, деленного на среднеквадратичную ошибку (MSE) между сгенерированным и исходным изображениями.

Так как PSNR опирается исключительно на попиксельную ошибку, оперируя только разницей в уровнях каналов, нежели визуальным восприятием, использование лишь этой метрики приводит к низкому качеству реконструкции в реальных условиях, когда необходимо получить наиболее близкое качественное оценивание с человеком. Однако из-за необходимости сравнения научных работ и отсутствия абсолютных перцептивных метрик, PSNR остается широко используемым сравнительным критерием для оценки качества работы алгоритмов<sup>1</sup>.

Другой подход оценки качества изображений опирается на высокую степень адаптивования для извлечения структур в изображениях зрительной системы человека, предлагая индекс структурного сходства (SSIM) для измерения структурного сходства с точки зрения яркости и контрастности двух изображений<sup>2</sup>.

Однако исследователи сталкиваются с тем, что эти методы оценки не позволяют реально оценить качество изображения. Вместо этого они численно показывают схожесть HR-изображения с анализируемым. Чтобы обойти это ограничение, иссле-

<sup>1</sup> Wang Z., Chen J., Hoi S. C. H. Deep Learning for Image Super-Resolution: A Survey // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2021. Vol. 43. No. 10. Pp. 3365–3387.

<sup>2</sup> Wang Z., et al. Image quality assessment: from error visibility to structural similarity // *IEEE Transactions on Image Processing*. 2004. Vol. 13. No. 4. Pp. 600–612.

дователи стали использовать VGG-сети<sup>1</sup>, обученные на данных экспертной группы, для оценки генерируемых изображений. Сложностью в этом случае является то, что эксперты дают оценку маленькой выборке изображений из публичных датасетов, что является проблемой при применении этих же методов к специфичным изображениям типа аэрофотосъемки и спутниковых снимков, так как спутниковые снимки обладают отличительными особенностями, например, обилием мелких объектов островного типа, преобладанием определенного спектра и т. д.

Для решения проблемы оценивания качества супер-разрешения спутниковых снимков и аэрофотосъемки лесных зон разработан метод оценки с помощью сегментирующей нейросети, используемой в качестве критика.

### Основная часть

Важной особенностью супер-разрешения спутниковых изображений является целенаправленность обработки изображений. Как правило, исследователь желает получить улучшение каких-то конкретных образов на изображении, например – техники<sup>2</sup> или промышленных зон<sup>3</sup>. В наших исследованиях мы нацелены на супер-разрешение лесных зон и фермерских территорий, в связи с чем необходим метод оценки качества восстановления текстур крон деревьев.

Результатом поисков стал метод, использующий U-Net сегментатор в качестве эксперта, который производит обработку HR- (исходного, в высоком качестве) и SR-изображений (восстановленного). Для каждого пикселя изображений нейросеть должна сделать высказывание о вероятности принадлежности его к образу дерева. Таким образом, выходным сигналом являются одноканальные маски исходных изображений, на которых выделены образы деревьев. Далее, используя статистические методы, можно сопоставить эти две маски на предмет совпадения.

В данном случае, при обучении на прецедентах, использование нейросети позволяет выявить признаки, характерные для искомого класса образов; при этом, также выявить признаки, которые точно ему не характерны. Из-за сложности системы образов объектов лесного массива не представляется возможным использовать иные методы для точного выделения этих признаков и свойств, точно характерных или не характерных для искомого объектов на кадре.

При этом, в случае, если обученный эксперт сможет выявлять искомые образы с точностью не ниже 80 %, сравнение артефактов его работы на разных фрагментах снимков может позволить отбросить ошибку классификации, т. к. в таком случае разница между восстанавливаемыми характеристиками в SR-фрагменте в сравнении с HR-фрагментами будет достаточно мала для практического применения.

<sup>1</sup> Shelhamer E., Long J., Darrell T. Fully Convolutional Networks for Semantic Segmentation // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2017. Vol. 39, no. 4. Pp. 640–651. <https://doi.org/10.1109/TPAMI.2016.2572683>

<sup>2</sup> Rabbi J., et al. Small-Object Detection in Remote Sensing Images with End-to-End Edge-Enhanced GAN and Object Detector Network // Remote Sensing. 2020. Vol. 12. Pp. 1432.

<sup>3</sup> Nguyen N. L., et al. Self-supervised multi-image super-resolution for push-frame satellite images // IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). 2021. Pp. 1121–1131. <https://doi.org/10.1109/CVPRW53098.2021.00123>

Для вычисления количественной характеристики качества восстановления признаков, присущих образам, классификации которой обучен эксперт, сравниваются логиты сегментации SR-изображения и соответствующему ему HR-изображения. Для этого используется M-score для непрерывных вероятностей:

$$Mscore = \frac{2 \sum_{x,y} Y_{xy} \widehat{Y}_{xy}}{\sum_{x,y} Y_{xy}^2 + \sum_{x,y} \widehat{Y}_{xy}^2}, \quad (1)$$

$$\widehat{Y} = \sigma(l_{\Theta}(G_{\Theta_G}(LR))), \quad (2)$$

$$Y = \sigma(l_{\Theta}(HR)). \quad (3)$$

Совпадение формы выделенных объектов при допустимом уровне расхождения (<10 %) будет интерпретироваться как подтверждение корректной реконструкции структуры в SR-фрагментах. Таким образом, экспертная U-Net выполняет функцию независимого валидационного инструмента, позволяющего количественно оценить согласованность результатов супер-разрешения с эталонными признаковыми структурами, извлекаемыми из HR-данных.

**Тестовые модели супер-разрешения.** Основной тестовой моделью стала ESRGAN как сеть, имеющая одну из высоких оценок в научном сообществе и предоставляющая удобный фреймворк для последующих ее модификаций<sup>1</sup>. Архитектура ESRGAN (рис. 1) формируется вокруг глубокой генеративной модели, в которой канал реконструкции основан на каскаде плотных остаточных блоков с пропуском по каналам (RRDB), что обеспечивает сохранение устойчивого градиентного потока на большой глубине сети. Внутренняя организация каждого блока строится на объединении локальных признаков, при котором промежуточные представления соединяются конкатенацией, а последующая свертка преобразует их в компактное пространство признаков, позволяя модели улавливать сложные высокочастотные зависимости. Между блоками используется остаточное соединение, уменьшающее риск деградации при увеличении глубины и создающее условия для стабильного обучения.

Другие тестовые модели – GISSRGAN и UGISSRGAN<sup>2</sup> (рис. 2). Они являются идейным продолжением ESRGAN, но при этом используют дополнительный канал сопутствующих данных для снижения шумности RRDB. Блок кодирования сопутствующих данных (UGISDFB) генерирует управляющий тензор для блоков кодирования LR-изображения. Адаптер внутри SMRRDB выбирает 1 канал из управляющего тензора и использует его как маску, применяемую к сигналу, кодирующему LR-изображение.

1 Wang Z., Chen J., Hoi S. C. H. Deep Learning for Image Super-Resolution: A Survey // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2021. Vol. 43, no. 10. Pp. 3365–3387.

2 Sharshov I., et al. Super-Resolution of Satellite Images Using Landsat Data // Applied Intelligence. Singapore: Springer Nature, 2025. Pp. 83–93.

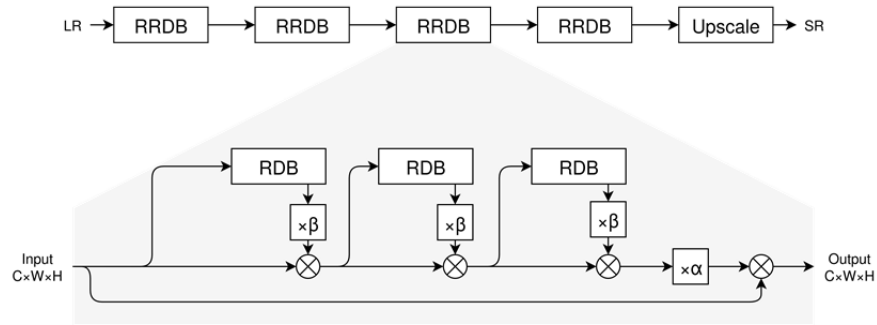


Рис. 1. Структурная схема генератора ESRGAN




Рис. 2. Архитектура UGISSRGAN

**Методика обучения тестовых моделей.** Процесс обучения состоит из 2 основных стадий: предобучения и обучения. Первый этап рассматривался С. Ванг<sup>1</sup>. Он включает обучение PSNR-ориентированной модели. Основным отличием нашего предобучения стало использование  $L_2$  функции потерь и меньшими значениями  $\text{lr} = 10^{-5}$ . Чтобы исключить нежелательное влияние необученных критиков, они также обучались с той же скоростью, используя бинарную кросс-энтропию в качестве функции потерь.

**Этап обучения** является состязательным – генератор учится обманывать двух критиков: критика SR-изображений и критика сигнального тензора блока UGISDFB. Соответственно, определяются сети критиков SR-изображений  $D_{\theta_D}$  и управляющего сигнала  $GD_{\theta_{GD}}$ , которые обучаются поочередно вместе с генератором  $G_{\theta_G}$ . Согласно Гудфеллоу<sup>2</sup>, решается минимакс задача:

$$\min_{\Theta_G} \max_{\Theta_D} \max_{\Theta_{GD}} (Disc_G + Disc_{GD} + Adv_G + Adv_{GD}), \quad (4)$$

$$Disc_G = E_{X_{LR}} [\log D(HR, \Theta_D)], \quad (5)$$

$$Disc_{GD} = E_{X_{LR}} [\log GD(LCMAP, \Theta_{GD})], \quad (6)$$

<sup>1</sup> Wang X., et al. ESRGAN: Enhanced super-resolution generative adversarial networks: Lecture Notes // Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). 2019. Vol. 11133 LNCS. Pp. 63–79.

<sup>2</sup> Goodfellow I. J., et al. Generative Adversarial Networks // Advances in neural information processing systems. 2014. Vol. 27. Pp. 1–9.

$$Adv_G = E_{X_{LR}} \left[ \log \left( 1 - D \left( G(LR, CC, \Theta_G), \Theta_D \right) \right) \right], \quad (7)$$

$$Avg_{GD} = E_{X_{LR}} \left[ \log \left( 1 - GD \left( UGISDFB(CC, \Theta_G), \Theta_{GD} \right) \right) \right]. \quad (8)$$

Оптимизация производилась с помощью Adam<sup>1</sup> с параметрами  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ ,  $\epsilon = 10^{-6}$ . Более подробно методика описана в исследовании этих архитектур<sup>2</sup>.

**Датасеты.** Так как исследование направлено на обработку спутниковых снимков, необходим источник обучающих данных, который обладает хорошей разрешающей способностью и, одновременно с этим, имеет геопривязку и максимально схожую проекцию кадра на плоскость. Одним из таких источников является коллекция ортоснимков высокого разрешения (HRO) в базе NEON<sup>3</sup>. Эти снимки сделаны с помощью аэрофотосъемки, а затем отредактированы для улучшения стыковки с элементами ландшафта и привязаны к одной из координатных сеток, принятых EPSG. Для формирования конечного снимка цифровое орто-изображение в базе может быть собрано из нескольких фотографий.

Источником дополнительных данных геоинформационных систем является набор коллекций Landsat<sup>4</sup>. Данные Landsat 8 и 9, предоставляемые Геологической службой США (USGS), содержат продукты уровня Collection 2 Level-2 Science Products (L2SP), которые включают отражение от поверхности (Surface Reflectance, SRef) и температуру поверхности (Surface Temperature, ST). Они позволяют проводить анализ на основе данных высокого пространственного разрешения с минимальной потребностью в дополнительной обработке.

Также для обучения использованы данные коллекции CCDC (Continuous Change Detection Classification v1.3), собранные в 2021 году. Коллекция предоставляет размеченные по 8 классам снимки территории США, характеризующие поверхность. Эти данные не проецировались на фрагменты HRO и были использованы при обучении критика для блока UGISDFB.

**Сравнение PSNR и SSIM тестовых моделей.** В ходе эксперимента обучены модели: GISSRGAN, UGISSRGAN, ESRGAN на данных NEON с использованием данных Landsat8-9 и LR-изображения в качестве сопутствующих данных. Размер датасета составил 79659 изображений размером 512 px с пространственным разрешением

<sup>1</sup> Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization // 3rd International Conference for Learning Representations. San Diego, 2017. Pp. 1–15.

<sup>2</sup> Sharshov I., et al. Super-Resolution of Satellite Images Using Landsat Data // Applied Intelligence. Singapore: Springer Nature, 2025. Pp. 83–93.

<sup>3</sup> National Ecological Observatory Network (NEON). High-resolution orthorectified camera imagery mosaic (DP3.30010.001) / National Ecological Observatory Network (NEON). National Ecological Observatory Network (NEON), 2024.

<sup>4</sup> Earth Resources Observation and Science (EROS) Center. (2020). Landsat 8-9 Operational Land Imager / Thermal Infrared Sensor Level-2, Collection 2 [dataset]. U.S. Geological Survey. <https://doi.org/10.5066/P9OGBGM6>

ем 4 пкс / м. Из них 90 % отобрано для обучения, 10 % для валидации и обучения критика.

Каждая модель содержала 20 блоков кодирования (RRDB). Этап предобучения для всех моделей длился 1000 итераций, этап обучения длился 300000 итераций для ESRGAN и 500000 для GISSRGAN и UGISSRGAN. Разница в длительности обучения обусловлена низкой устойчивостью ESRGAN к галлюцинированию, о чем писали авторы. За этот же период GISSRGAN и UGISSRGAN не успевают достичь плато обучения.

В табл. 1 приведено сравнение метрик результатов тестирования обученных нейросетей. Показатели вычислялись по изображениям, в 2 раза меньше SR размеров (сжатие производилось с использованием линейной интерполяции). Также произведено качественное сравнение восстановления текстуры листвы, пример генерации представлен на рис. 3.

Таблица 1

Сравнительные результаты валидации обученных нейросетей

Модель нейросети	PSNR	SSIM
GISSRGAN	21,5950	0,3876
UGISSRGAN	<b>25,8669</b>	<b>0,4223</b>
SRGAN	21,6363	0,3605

**Обучение модели эксперта** проводилось в течение 100 эпох оптимизатором Adam с использованием бинарной кросс-энтропии как функции потерь. Для оценки точности использовалась метрика M-score. При обучении была поставлена цель получить значение M-score выше 0,9. Это связано с ошибками ручной разметки с помощью полигонов, при которой крайне сложно точно отследить реальную форму кроны. Также стоит отметить влияние артефактов плиточной съемки и влияние ветра на деревья. Ветер сдвигает верхнюю часть кроны и «разбрасывает» ветви с листвой, поэтому сложнее оценить реальную форму кроны.

Результаты оценки обученной модели представлены в таблице 2. Модель сегментатора имеет достаточную точность по метрике M-score, при этом стоит отметить крайне высокий показатель Precision. При оценке метрик можно также отметить достаточно высокий показатель FN (ложноотрицательные): такое значение связано с тем, что при разметке полигон размеченных данных всегда чуть больше, чем реальная крона дерева из-за ручной разметки и конечного количества точек, с помощью которых производилось приближение к реальной кроне на снимке. Также такие показатели показывают консервативность модели, которая склонна отсекать незнакомые или сомнительные характеристики образов. Однако сеть сегментатора допускает ошибки при разметке крон, которые не попадают полностью в кадр.




Рис. 3. Качественное сравнение восстановления текстуры листвы при супер-разрешении  $\times 4$

Таблица 2

**Результаты оценки точности модели критика после обучения**

Метрика	Значение
TP	0,9315
TN	0,9918
FP	0,0082
FN	0,0685
Precision	0,9913
Recall	0,9315
M-score	0,9239
F1-score	0,9605

**Оценка качества** супер-разрешенных изображений произведена с использованием критика, обученного сегментировать кроны деревьев. Результаты эксперимента представлены в таблице 3 метриками M-score и F1-score, что позволяет сделать вывод о том, что разработанный метод лучше подходит для использования в задачах сегментации спутниковых снимков с низким пространственным разрешением.

Таблица 3

**Результаты оценки адекватности работы моделей супер-разрешения**

Метрика	UGISSRGAN	GISSRGAN	ESRGAN	LR (контроль)
Precision	<b>0,9416</b>	0,8627	0,8569	1,0
Recall	<b>0,9301</b>	0,8714	0,8565	0,0180
M-score	<b>0,8794</b>	0,7653	0,7494	0,0180
F1-score	<b>0,9358</b>	0,8670	0,8567	0,0354

### Выводы

В ходе исследований UGISSRGAN показала самое лучшее восстановление листвы по сравнению с рассмотренными аналогами, при этом оценка с помощью нового метода продемонстрировала согласованные результаты как с PSNR показателями, так и с оценочным тестом.

Представленный метод позволяет производить оценку качества супер-разрешения изображений с точки зрения качества восстановления характеристик, присущих сложным текстурам целевых классов (деревьев в случае данного исследования). Это позволяет применять данный метод оценки как опорный при исследовании методов супер-разрешения изображений. В последствии этот метод можно расширить на другие области путем замены обучающего датасета эксперта и целевых классов.

### References

Earth Resources Observation and Science (EROS) Center. (2020). Landsat 8-9 Operational Land Imager / Thermal Infrared Sensor Level-2, Collection 2 [dataset]. *U. S. Geological Survey*. <https://doi.org/10.5066/P9OGBGM6>

Goodfellow I. J., et al. Generative adversarial networks. *Advances in neural information processing systems*, 2014, vol. 27, pp. 1–9.

Kingma D. P. Adam: a method for stochastic optimization. *3rd International Conference for Learning Representations*. San Diego, 2017.

National Ecological Observatory Network (NEON). High-resolution orthorectified camera imagery mosaic (DP3.30010.001). *National Ecological Observatory Network (NEON). National Ecological Observatory Network (NEON)*, 2024.

Nguyen N. L., et al. Self-supervised multi-image super-resolution for push-frame satellite images. *IEEE / CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 2021, pp. 1121–1131. <https://doi.org/10.1109/CVPRW53098.2021.00123>

Rabbi J., et al. Small-object detection in remote sensing images with end-to-end edge-enhanced GAN and object detector network. *Remote Sensing*, 2020, vol. 12, pp. 1432.

Sharshov I., et al. Super-resolution of satellite images using Landsat Data. *Applied Intelligence*. Singapore: Springer Nature, 2025, pp. 83–93.

Shelhamer E., Long J., Darrell T. Fully convolutional networks for semantic segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, vol. 39, no. 4, pp. 640–651. <https://doi.org/10.1109/TPAMI.2016.2572683>

Wang X., et al. ESRGAN: Enhanced super-resolution generative adversarial networks. *Computer Science (including subseries lecture notes in Artificial Intelligence and lecture notes in Bioinformatics)*. 2019, vol. 11133 LNCS, pp. 63–79.

Wang Z., et al. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*. 2004, vol. 13, no. 4, pp. 600–612.

Wang Z., Chen J., Hoi S. C. H. Deep Learning for Image Super-Resolution. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, vol. 43, no. 10, pp. 3365–3387.

### Сведения об авторах

**Иван Юрьевич Шаршов** – старший преподаватель; <https://orcid.org/0000-0001-8001-9454>, [sharshov-ivan@yandex.ru](mailto:sharshov-ivan@yandex.ru), Северный (Арктический) федеральный университет им. М. В. Ломоносова (д. 17, набережная Северной Двины, 163002 Архангельск, Россия); **Ivan Iu. Sharshov** – Senior Lecturer, <https://orcid.org/0000-0001-8001-9454>, [sharshov-ivan@yandex.ru](mailto:sharshov-ivan@yandex.ru), Northern (Arctic) Federal University named after M. V. Lomonosov (17, Severnaya Dvina nab., 163002 Arkhangelsk, Russia).

**Владимир Валерьевич Березовский** – кандидат технических наук, доцент; <https://orcid.org/0000-0003-1694-5896>, [v.berezovsky@narfu.ru](mailto:v.berezovsky@narfu.ru), Северный (Арктический) федеральный университет им. М. В. Ломоносова (д. 17, набережная Северной Двины, 163002 Архангельск, Россия); **Vladimir V. Berezovsky** – Candidate of Technical Sciences, Associate Professor, <https://orcid.org/0000-0003-1694-5896>, [v.berezovsky@narfu.ru](mailto:v.berezovsky@narfu.ru), Northern (Arctic) Federal University named after M. V. Lomonosov (17, Severnaya Dvina nab., 163002 Arkhangelsk, Russia).

**Заявленный вклад авторов:** авторы сделали разный вклад в подготовку публикации, что отражено в последовательности персоналий авторского коллектива. Авторы заявляют об отсутствии конфликта интересов.

**Contribution of the authors:** the authors made different contributions to the preparation of the publication, which is reflected in the sequence of personalities of the author's team. The authors declare no conflicts of interests.

---

Статья поступила в редакцию 02.12.2025; одобрена после рецензирования 25.12.2025; принята к публикации 14.01.2026.

The article was submitted 02.12.2025; Approved after reviewing 25.12.2025; Accepted for publication 14.01.2026.