

УДК 004.8

DOI: [10.26102/2310-6018/2025.50.3.036](https://doi.org/10.26102/2310-6018/2025.50.3.036)

Программный комплекс улучшения качества распознавания номерных знаков на основе нейросетевых моделей суперразрешения

Л.М. Ахметов, И.В. Аникин✉

*Казанский национальный исследовательский технический университет
им. А.Н. Туполева-КАИ, Казань, Российская Федерация*

Резюме. Распознавание государственных регистрационных знаков (ГРЗ) является одной из ключевых задач для интеллектуальных транспортных систем. На практике такие факторы, как размытие, шум, неблагоприятные погодные условия или съемка с большого расстояния, приводят к получению изображений низкого разрешения (Low Resolution, LR), что существенно снижает надежность распознавания. Перспективным решением данной проблемы является применение методов суперразрешения (Super-Resolution, SR), способных восстанавливать изображения высокого разрешения (High Resolution, HR) из соответствующих им LR-версий. Настоящая работа посвящена исследованию и разработке программного комплекса, использующего нейросетевые модели суперразрешения для улучшения качества и точности распознавания номерных знаков. Программный комплекс реализует нейросетевые архитектуры обнаружения объектов YOLO (You Only Look Once), алгоритм трекинга объектов SORT (Simple Online and Realtime Tracking) и модели суперразрешения для улучшения изображений номерных знаков. Такой подход обеспечивает достижение высокой точности распознавания ГРЗ даже при работе с изображениями, полученными в сложных условиях съемки, характеризующихся низким качеством или разрешением. Результаты экспериментов демонстрируют, что предложенный подход способен повысить точность распознавания ГРЗ на изображениях низкого разрешения. Качество восстановления изображений оценивалось с использованием метрик PSNR и SSIM, подтвердивших улучшение визуальных характеристик номерных знаков для наиболее эффективных моделей. Разработанный программный комплекс обладает широким потенциалом практического применения и может быть интегрирован в различные системы, например, для контроля доступа на охраняемые территории, мониторинга и анализа дорожного движения, автоматизации парковочных комплексов, а также в составе решений для обеспечения общественной безопасности. Гибкость реализованной архитектуры позволяет адаптировать систему под специфические требования с модификациями, что подчеркивает ее универсальность и практическую значимость.

Ключевые слова: распознавание номерных знаков, машинное зрение, глубокие нейронные сети, суперразрешение, обнаружение объектов, трекинг объектов.

Для цитирования: Ахметов Л.М., Аникин И.В. Программный комплекс улучшения качества распознавания номерных знаков на основе нейросетевых моделей суперразрешения. *Моделирование, оптимизация и информационные технологии.* 2025;13(3). URL: <https://moitvvt.ru/ru/journal/pdf?id=2020> DOI: 10.26102/2310-6018/2025.50.3.036

Software for improving the quality of license plate recognition based on super-resolution neural network models

L.M. Akhmetov, I.V. Anikin✉

*Kazan National Research Technical University named after A.N. Tupolev-KAI, Kazan,
the Russian Federation*

Abstract. Recognition of license plates (LP) is one of the key tasks for intelligent transport systems. In practice, such factors as blur, noise, adverse weather conditions or shooting from a long distance lead to obtaining low-resolution (LR) images, which significantly reduces the reliability of recognition. A promising solution to this problem is the use of super-resolution (SR) methods capable of restoring high-resolution (HR) images from the corresponding LR versions. This paper is devoted to the research and development of a software package using neural network super-resolution models to improve the quality and accuracy of LP recognition. The software package implements the YOLO (You Only Look Once) neural network architectures for object detection, the SORT (Simple Online and Realtime Tracking) object tracking algorithm and super-resolution models to improve LP images. This approach ensures high accuracy of LP recognition even when working with images obtained in difficult shooting conditions characterized by low quality or resolution. The experimental results demonstrate that the proposed approach can improve the accuracy of LP recognition in low-resolution images. The image restoration quality was assessed using the PSNR and SSIM metrics, which confirmed the improvement of the visual characteristics of LP for the most effective models. The developed software package has a wide potential for practical application and can be integrated into various systems, for example, for access control to protected areas, traffic monitoring and analysis, automation of parking complexes, as well as as part of solutions for ensuring public safety. The flexibility of the implemented architecture allows you to adapt the system to specific requirements with modifications, which emphasizes its versatility and practical significance.

Keywords: license plates recognition, computer vision, deep neural networks, superresolution, objects detection, objects tracking.

For citation: Akhmetov L.M., Anikin I.V. Software for improving the quality of license plate recognition based on super-resolution neural network models. *Modeling, Optimization and Information Technology*. 2025;13(3). URL: (In Russ.). <https://moitvvt.ru/ru/journal/pdf?id=2020> DOI: 10.26102/2310-6018/2025.50.3.036

Введение

Системы автоматического распознавания государственных регистрационных знаков (ГРЗ) являются неотъемлемым компонентом современных интеллектуальных транспортных систем, обеспечивая контроль доступа, управление транспортными потоками и содействие в обеспечении общественной безопасности. Однако их эффективность существенно снижается при обработке изображений низкого разрешения, что представляет собой существенное ограничение в реальных условиях эксплуатации.

Снижению качества распознавания способствуют множество факторов, к ним относятся размытие изображения вследствие движения транспортного средства, наличие визуальных шумов различной природы, искажения, обусловленные неблагоприятными атмосферными условиями, такими как дождь, снег или туман. Дополнительное влияние оказывают ограничения используемых оптических систем видеокамер и съемка объектов с дальних дистанций.

В качестве перспективного решения данной проблемы активно рассматриваются методы повышения разрешения изображений (Super Resolution, SR). Применение технологий SR позволяют восстанавливать детали в изображениях низкого разрешения (LR), тем самым улучшая качество визуальных данных. Низкое разрешение исходного изображения ведет к утрате мелких, но критически значимых деталей, таких как контуры символов, что значительно усложняет их точную идентификацию. Таким образом, интеграция SR в процесс обработки изображений ГРЗ представляется не просто улучшением, а зачастую необходимым условием для достижения требуемой точности распознавания в сложных условиях [1].

Актуальность исследования заключается в повышении надежности систем распознавания ГРЗ при работе с изображениями, качество которых снижено из-за

условий реальной эксплуатации. Особое внимание уделяется современным методам SR, основанным на архитектурах глубоких нейронных сетей. Данные подходы обладают потенциалом не только для восстановления деталей, утраченных из-за низкого разрешения, но и для смягчения влияния других искажающих факторов, например, шума или размытия, тем самым позволяя преодолевать ограничения как съемочного оборудования, так и среды.

Цель данной работы заключается в оценке влияния различных нейросетевых SR-моделей на итоговую точность распознавания ГРЗ при неблагоприятных условиях съемки.

Для достижения поставленной цели в рамках исследования решаются следующие задачи:

1. Проведение сравнительного анализа эффективности различных архитектур SR-моделей в контексте повышения качества распознавания ГРЗ.
2. Определение оптимальной конфигурации модели суперразрешения для специфической задачи распознавания ГРЗ, с учетом вычислительной эффективности.
3. Разработка и реализация программного комплекса распознавания ГРЗ с применением методов SR.
4. Проведение экспериментального исследования эффективности методов суперразрешения на разнородных наборах данных.

Практическая значимость работы обусловлена возможностью внедрения разработанного программного комплекса в существующие системы видеоаналитики для транспортной инфраструктуры.

Материалы и методы

Предлагаемый подход. В рамках данного исследования была разработана многокомпонентная система распознавания автомобильных номеров, основанная на последовательной интеграции алгоритмов компьютерного зрения и глубокого обучения.

На первом этапе осуществляется обнаружение транспортных средств в кадре. Для этого применяется детектор объектов на основе архитектуры YOLO (You Only Look Once), в частности, используется модификация YOLOv12n, выбранная по критерию оптимального соотношения между скоростью обработки и точностью детекции для задач реального времени. На следующем этапе выполняется локализация непосредственно номерных знаков, для этого применяется модель YOLOv12, специально дообученная на наборе данных, содержащая изображения ГРЗ. Ключевой особенностью данного подхода является применение детектора номерных знаков не ко всему кадру, а исключительно к областям интереса (Regions of Interest, ROI), соответствующим ранее обнаруженным транспортным средствам. Такой двухэтапный процесс позволяет значительно снизить вычислительную нагрузку и уменьшить вероятность ложных срабатываний детектора номерных знаков, что способствует стабильной работе системы в условиях вариативности ракурсов съемки, частичных перекрытий объектов и изменений освещенности [2].

Для обеспечения непрерывности идентификации номерных знаков во времени используется алгоритм отслеживания объектов SORT (Simple Online and Realtime Tracking). Данный алгоритм сочетает предсказание положения объектов на основе фильтра Калмана с ассоциацией обнаруженных объектов с существующими траекториями при помощи венгерского алгоритма, что позволяет поддерживать стабильное отслеживание номерных знаков, даже в случаях их временного исчезновения из поля зрения камеры или частичного перекрытия другими объектами.

Распознавание символов на локализованных изображениях номерных знаков осуществляется с помощью каскада из двух нейросетевых моделей. Первой применяется

модель Spatial Transformer Network (STN), предназначенная для нормализации изображения. STN выполняет коррекцию перспективных и геометрических искажений, приводя изображение к стандартизированному виду. Этап нормализации является критически важным, поскольку он компенсирует вариации, вызванные ракурсом съемки, и подготавливает изображение для последующего распознавания символов [3]. Для распознавания символов используется модель License Plate Recognition Network (LPRNet). LPRNet представляет собой сверточную нейронную сеть, архитектура которой оптимизирована для задачи идентификации последовательности символов на российских автомобильных номерах [4]. По сравнению с традиционными подходами на основе оптического распознавания символов (OCR), LPRNet демонстрирует высокую точность при меньших вычислительных затратах. Совместное использование STN и LPRNet обеспечивает устойчивость системы распознавания в сложных условиях, таких как неравномерное освещение, наличие бликов или частичное загрязнение номерного знака.

Важным компонентом разработанной системы являются методы суперрезолюции (SR), предназначенные для повышения качества изображений номерных знаков низкого разрешения. Модуль SR интегрируется в конвейер обработки перед этапом распознавания (STN и LPRNet). Применение таких методов способствуют увеличению точности распознавания символов, когда исходное изображение имеет недостаточное разрешение. Архитектура системы предусматривает возможность гибкого подключения различных SR моделей, позволяя выбирать оптимальный вариант, в зависимости от требований к качеству восстановления и имеющихся вычислительных мощностей.

Эффективность методов суперрезолюции оценивалась с использованием общепринятых показателей качества изображений. Среди них пиковое отношение сигнал/шум (PSNR, Peak Signal-to-Noise Ratio), которое количественно отражает степень искажений восстановленного изображения по сравнению с оригиналом, и индекс структурного сходства (SSIM, Structural Similarity Index), измеряющий сходство структурных элементов между изображениями. Вычисление значений PSNR и SSIM проводилось с применением стандартных реализаций, доступных в библиотеках компьютерного зрения, таких как scikit-image и OpenCV. Данные метрики применялись для сравнения изображений номерных знаков до и после применения SR в процессе обработки видеопотока, что позволило собрать статистику для анализа влияния SR на качество визуальных данных. Общая архитектура разработанного программного комплекса представлена на Рисунке 1.



Рисунок 1 – Архитектура программного комплекса
Figure 1 – Software architecture

Представленная на Рисунке 1 архитектура объединяет передовые подходы в области компьютерного зрения и глубокого обучения для решения задачи распознавания автомобильных номеров с высокой точностью и эффективностью, подтвержденной соответствующими метриками. Для того чтобы сделать разработанный программный комплекс доступным и удобным для конечного пользователя, была создана оболочка в виде графического пользовательского интерфейса. На Рисунке 2 представлен интерфейс программного комплекса.




Рисунок 2 – Интерфейс программного комплекса
Figure 2 – Software interface

Базовые модели суперразрешения. В настоящее время исследования в области улучшения качества изображений и распознавания ГРЗ активно развиваются в нескольких ключевых направлениях, что свидетельствует о значительном прогрессе и растущем интересе к этим темам. На текущем этапе можно выделить два взаимосвязанных направления: совершенствование алгоритмов детекции номерных знаков и улучшение методов распознавания символов, что в совокупности формирует основу для создания надежной системы распознавания.

Современные методы суперразрешения, играющие ключевую роль в задачах компьютерного зрения, развиваются по трем основным направлениям: генеративно-сопоставительные сети, трансформерные архитектуры и гибридные подходы. Эти технологии особенно актуальны для систем распознавания номерных знаков, где повышение качества низкодетализированных изображений, полученных с камер видеонаблюдения, напрямую влияет на точность детекции и последующего анализа символов.

Генеративно-сопоставительные сети (GAN) стали прорывным направлением, начиная с работы SRGAN (2016) [5], которая впервые продемонстрировала возможность генерации фотореалистичных изображений с высоким разрешением. Дальнейшее развитие этого подхода связано с архитектурными усовершенствованиями: модель ESRGAN (2018) [6] повысила детализацию за счет устранения артефактов, а Real-ESRGAN (2021) расширила применимость метода за счет адаптации к реальным искажениям, таким как шумы и сжатие. Практическую ценность дополнили BSRGAN (2021) [7], предложившая алгоритмы для «слепой» суперразрешения, не требующие

предварительной информации о деградации изображений, и CUGAN (2021) [8], внедрившая механизмы контроля восстановления для гибкой настройки результатов.

Трансформерные архитектуры, первоначально разработанные для задач обработки естественного языка, начали активно применяться в компьютерном зрении после публикации работы [9]. Модель SwinIR модифицировала архитектуру Swin Transformer для задач суперразрешения, добавив механизмы локального и глобального внимания. На основе SwinIR была создана усовершенствованная модель Swin2SR, повысившая устойчивость обучения за счет двухэтапной оптимизации функции потерь: сначала минимизации ошибки восстановления низких частот, затем – детализации высоких частот. Это позволило снизить переобучение на шумных данных и улучшить качество восстановления текстур.

В 2023 году модель SRFormer [10] представила модифицированный механизм самовнимания, сокративший вычислительные затраты без потери качества, а HAT [11] достигла нового уровня детализации за счет комбинации канального и оконного внимания.

Дополнительные методы, комбинирующие преимущества разных подходов. Например, MM-RealSR интегрировала метрическое обучение для автоматической оценки степени деградации изображения, что повысило точность восстановления [12]. Алгоритм AdaCode расширил адаптивность моделей за счет динамического кодирования, позволяющего обрабатывать разнородные искажения в рамках единой архитектуры [13].

Результаты и обсуждение

В рамках экспериментального исследования был проведен комплексный анализ нейросетевых моделей суперразрешения, с целью оценки их влияния на повышение точности распознавания ГРЗ. Исследование проводилось на наборе данных, полученных из видеозаписи движения одного автомобиля с известным эталонным номером, снятым в различных условиях и разным положением в кадре.

Набор включал 180 кадров, что позволило оценить стабильность результатов, при увеличении объема анализируемой информации. Точность распознавания оценивалась путем сравнения результатов с известным эталонным номером. Эксперимент включал анализ объективных показателей качества восстановленных изображений с помощью метрик PSNR и SSIM. Результаты экспериментов представлены в Таблице 1.

Для каждой SR-модели, а также для базового случая без применения SR, вычислялась точность распознавания символов ГРЗ в четырех различных сценариях:

1. Оригинал: распознавание на исходном LR-изображении без какой-либо обработки.
2. Оригинал + STN: распознавание на исходном LR-изображении после применения модуля STN для коррекции геометрических искажений.
3. SR: распознавание на изображении, улучшенном с помощью SR-модели, без применения STN.
4. SR + STN: распознавание на изображении, улучшенном с помощью SR-модели, с последующим применением STN.

Таблица 1 – Сводные результаты оценки моделей суперразрешения
Table 1 – Summary results of evaluation of super-resolution models

Модель	SR, %	SR+STN, %	PSNR	SSIM
SRGAN	0,00	0,00	14,26	0,0043
Real HAT	65,00	80,00	32,48	0,9033

Таблица 1 (продолжение)
Table 1 (continued)

Swin2SR_RW_SR	56,11	82,22	34,67	0,9367
Real-CUGAN-nod	58,89	80,00	32,07	0,8766
BSRGAN	54,44	80,00	33,56	0,9182
MMRealSRGAN	51,67	77,78	28,28	0,8473
RealESRNet	46,67	82,22	30,68	0,8452
RealESRGAN	41,11	77,78	29,42	0,8407
realSR_BSRGAN	36,11	77,22	28,46	0,8577
SRFormer_S	36,11	69,44	27,59	0,7838
realSR_BSRGAN_SwinIR	36,11	69,44	27,59	0,7838
4xFrankendata	27,22	65,56	29,87	0,8573
AdaCode_SR_X4	21,11	67,22	28,95	0,8027
Real_CUGAN_dns	2,22	17,22	30,62	0,7952

Анализ точности системы начался с базовой конфигурации, не использующей методы улучшения, где точность составила 52,78 %. Интеграция модуля STN для геометрической нормализации изображений номерных знаков привела к значительному росту этого показателя до 83,89 %, подтверждая критическую важность коррекции искажений для успешного распознавания. Отдельно была изучена эффективность моделей суперразрешения (SR) в сценарии их применения без этапа STN-нормализации. При таком подходе наивысшую точность, равную 65,00 %, продемонстрировала модель Real_HAT (Рисунок 3).



Рисунок 3 – Модель Real_HAT
Figure 3 – Real_HAT model

Этот показатель заметно превосходит базовый уровень точности (52,78 %), указывая на потенциал SR для улучшения читаемости номеров даже без явной геометрической коррекции. Высокую производительность также показали модели Real-CUGAN-nod (58,89 %), Swin2SR_RW_SR (56,11 %) (Рисунок 4) и BSRGAN (54,44 %).




Рисунок 4 – Модель Swin2SR_RW_SR
Figure 4 – Swin2SR_RW_SR model

Напротив, модели SRGAN (0 %) (Рисунок 5) и Real_CUGAN_dns (2,22 %) оказались практически неработоспособными в данных условиях, что подтверждает их ограничения для этой специфической задачи.



Рисунок 5 – Модель SRGAN
Figure 5 – SRGAN model

Переходя к совместному использованию методов, исследовалось комбинированное применение моделей SR и модуля STN. В этом случае максимальная точность распознавания была достигнута при использовании моделей RealESRNet и Swin2SR_RW_SR (Рисунок 6), обе показали результат 82,22 %. За ними следуют модели BSRGAN, Real-CUGAN-nod и Real_HAT с точностью 80,00 %.



Рисунок 6 – Модель Swin2SR_RW_SR+STN
Figure 6 – Swin2SR_RW_SR+STN model

Интересно отметить, что эти максимальные значения точности лишь незначительно уступают результату, полученному при использовании только STN на исходных изображениях (83,89 %). Это может указывать на то, что после эффективной геометрической коррекции с помощью STN, дальнейший вклад суперразрешения в точность распознавания становится менее выраженным для лучших моделей SR.

Сравнение точности распознавания ГПЗ для различных моделей SR представлено на Рисунке 7.




Рисунок 7 – Сравнительная диаграмма точности распознавания ГПЗ для различных моделей SR
Figure 7 – Comparative diagram of LP recognition for different SR models

Оценка объективного качества восстановленных изображений проводилась с использованием метрик PSNR и SSIM. По этим показателям лидирующую позицию уверенно заняла модель Swin2SR_RW_SR со значениями 34,67 дБ и 0,9367 соответственно.

Высокие метрики качества также были зафиксированы для моделей BSRGAN (33,56 дБ / 0,9182) и Real_HAT (32,48 дБ / 0,9033). Важно заметить, что лидеры по метрикам качества (Swin2SR_RW_SR, BSRGAN, Real_HAT) также показали высокую точность распознавания в сценарии SR без STN, что указывает на положительную корреляцию между визуальным качеством восстановления и распознаваемостью

символов для этих моделей. Сравнение метрик качества PSNR и SSIM восстановленных изображений для различных моделей SR представлено на Рисунке 8.




Рисунок 8 – Сравнение метрик качества (PSNR и SSIM) восстановленных изображений для различных моделей SR

Figure 8 – Comparison of quality metrics (PSNR and SSIM) of reconstructed images for different SR models

Заключение

В рамках проведенного исследования был разработан программный комплекс распознавания автомобильных номеров на основе нейросетевых моделей SR, ключевым элементом которого являлась интеграция методов SR для повышения качества обработки изображений низкого разрешения.

Основная цель исследования заключалась в оценке влияния различных нейросетевых SR-моделей на итоговую точность распознавания ГРЗ при неблагоприятных условиях съемки. Анализ проводился использованием метрики точности распознавания символов и объективных показателей качества восстановленных изображений PSNR и SSIM. Также оценивалось влияние модуля пространственной трансформации (STN) на точность при работе с исходными и улучшенными изображениями.

Экспериментальные данные подтвердили потенциал методов суперразрешения для улучшения точности систем распознавания ГРЗ. Установлено, что модели Swin2SR_RW_SR, BSRGAN и Real_HAT обеспечивают устойчиво высокие результаты на выборках разного объема, демонстрируя как значительное повышение точности распознавания, особенно с модулем STN, так и высокое качество восстановленных изображений по метрикам. Применение моделей SRGAN и Real_CUGAN_dns продемонстрировали непригодность для данной задачи, приводя к критическому падению точности из-за внесения значительных искажений в улучшенное изображение.

Важным выводом исследования является подтверждение значительной роли модуля STN для коррекции геометрических искажений. Применение данного модуля обеспечило существенный прирост точности распознавания как на исходных, так и на улучшенных SR-моделями изображениях. Комбинированное использование SR и STN позволило достичь наивысших показателей точности до 82,22 %, демонстрируя синергетический эффект от повышения разрешения и геометрической нормализации.

Анализ метрик PSNR и SSIM показал их полезность для оценки качества восстановления изображений, при этом модель Swin2SR_RW_SR стабильно лидировала по этим показателям. В ходе исследования было выявлено, что высокие показатели

метрик PSNR и SSIM не всегда гарантируют максимальную точность распознавания символов. Данный факт подчеркивает необходимость комплексной оценки SR-моделей, где приоритет отдается результативности в решении конечной прикладной задачи – в данном случае, корректного распознавания ГРЗ.

Полученные результаты могут быть использованы при проектировании и оптимизации систем видеоаналитики для транспортной инфраструктуры.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Vašek V., Franc V., Urban M. License Plate Recognition and Super-Resolution from Low-Resolution Videos by Convolutional Neural Networks. In: *BMVC 2018: Proceedings of British Machine Vision Conference, 03–06 September 2018, Newcastle, UK*. BMVA Press; 2018. URL: <http://bmvc2018.org/contents/papers/0537.pdf>
2. Tian Yu., Ye Q., Doermann D. YOLOv12: Attention-Centric Real-Time Object Detectors. arXiv. URL: <https://arxiv.org/abs/2502.12524> [Accessed 15th June 2025].
3. Jaderberg M., Simonyan K., Zisserman A., Kavukcuoglu K. Spatial Transformer Networks. In: *Advances in Neural Information Processing Systems 28: Annual Conference on Neural Information Processing Systems 2015, 07–12 December 2015, Montreal, QC, Canada*. 2015. P. 2017–2025.
4. Zherzdev S., Gruzdev A. LPRNet: License Plate Recognition via Deep Neural Networks. arXiv. URL: <https://arxiv.org/abs/1806.10447> [Accessed 15th June 2025].
5. Ledig Ch., Theis L., Huszár F., et al. Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 21–26 July 2017, Honolulu, HI, USA*. IEEE; 2017. P. 105–114. <https://doi.org/10.1109/CVPR.2017.19>
6. Wang X., Yu K., Wu Sh., et al. ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks. In: *Computer Vision – ECCV 2018 Workshops: Proceedings: Part V, 08–14 September 2018, Munich, Germany*. Cham: Springer; 2018. P. 63–79. https://doi.org/10.1007/978-3-030-11021-5_5
7. Zhang K., Liang J., Van Gool L., Timofte R. Designing a Practical Degradation Model for Deep Blind Image Super-Resolution. In: *2021 IEEE/CVF International Conference on Computer Vision (ICCV), 10–17 October 2021, Montreal, QC, Canada*. IEEE; 2021. P. 4771–4780. <https://doi.org/10.1109/ICCV48922.2021.00475>
8. Soviany P., Ardei C., Ionescu R.T., Leordeanu M. Image Difficulty Curriculum for Generative Adversarial Networks (CuGAN). In: *2020 IEEE Winter Conference on Applications of Computer Vision (WACV), 01–05 March 2020, Snowmass, CO, USA*. IEEE; 2020. P. 3452–3461. <https://doi.org/10.1109/WACV45572.2020.9093408>
9. Dosovitskiy A., Beyer L., Kolesnikov A., et al. An Image Is Worth 16×16 Words: Transformers for Image Recognition at Scale. In: *ICLR 2021: 9th International Conference on Learning Representations, 03–07 May 2021, Virtual Event, Austria*. 2021. URL: <https://arxiv.org/abs/2010.11929>
10. Bu Q., Park S., Khang M., Cheng Yi. SRFormer: Text Detection Transformer with Incorporated Segmentation and Regression. In: *Thirty-Eighth AAAI Conference on Artificial Intelligence, AAAI 2024, Thirty-Sixth Conference on Innovative Applications of Artificial Intelligence, IAAI 2024, Fourteenth Symposium on Educational Advances in Artificial Intelligence, EAAI 2024, 20–27 February 2024, Vancouver, Canada*. AAAI Press; 2024. P. 855–863.
11. Chen X., Wang X., Zhou J., Qiao Yu, Dong Ch. Activating More Pixels in Image Super-Resolution Transformer. In: *2023 IEEE/CVF Conference on Computer Vision and*

- Pattern Recognition (CVPR)*, 17–24 June 2023, Vancouver, BC, Canada. IEEE; 2023. P. 22367–22377. <https://doi.org/10.1109/CVPR52729.2023.02142>
12. Mou Ch., Wu Ya., Wang X., Dong Ch., Zhang J., Shan Yi. Metric Learning Based Interactive Modulation for Real-World Super-Resolution. In: *Computer Vision – ECCV 2022: 17th European Conference: Proceedings: Part XVII, 23–27 October 2022, Tel Aviv, Israel*. Cham: Springer; 2022. P. 723–740. https://doi.org/10.1007/978-3-031-19790-1_43
 13. Liu K., Jiang Yi., Choi I., Gu J. Learning Image-Adaptive Codebooks for Class-Agnostic Image Restoration. In: *2023 IEEE/CVF International Conference on Computer Vision (ICCV), 01–06 October 2023, Paris, France*. IEEE; 2023. P. 5350–5360. <https://doi.org/10.1109/ICCV51070.2023.00495>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Аникин Игорь Вячеславович, доктор технических наук, профессор, заведующий кафедрой систем информационной безопасности, Казанский национальный исследовательский технический университет им. А.Н. Туполева-КАИ, Казань, Российская Федерация.
e-mail: anikinigor777@mail.ru
ORCID: [0000-0001-9478-4894](https://orcid.org/0000-0001-9478-4894)

Igor V. Anikin, Doctor of Engineering Sciences, Professor, Head of Information Security Systems Department, Kazan National Research Technical University-KAI, Kazan, the Russian Federation.

Ахметов Линар Марселевич, магистрант кафедры систем информационной безопасности, Казанский национальный исследовательский технический университет им. А.Н. Туполева-КАИ, Казань, Российская Федерация.
e-mail: sib@kai.ru

Linar M. Akhmetov, Master's Degree student, Information Security Systems Department, Kazan National Research Technical University-KAI, Kazan, the Russian Federation.

Статья поступила в редакцию 08.07.2025; одобрена после рецензирования 06.08.2025; принята к публикации 08.08.2025.

The article was submitted 08.07.2025; approved after reviewing 06.08.2025; accepted for publication 08.08.2025.