

## Семантическая сегментация разметки взлетно-посадочной полосы с использованием нейронных сетей

А. Р. Музалевский

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

muzal2010@yandex.ru

**Аннотация.** Рассматриваются вопросы использования сверточной нейронной сети для решения задачи семантической сегментации горизонтальной разметки на взлетно-посадочной полосе на основе данных камеры. Данная задача имеет важное прикладное значение для повышения безопасности и автономности воздушных судов при посадке и рулении. Для обучения и валидации моделей был сформирован специализированный набор данных, включающий разнообразные изображения ВПП, полученные из открытых источников и размеченные вручную. В статье сравниваются две архитектуры сверточных нейронных сетей – U-Net и YOLO – с точки зрения точности сегментации, скорости инференса и устойчивости к изменениям условий освещения, погодным факторам и визуальным шумам. Оценивается применимость каждой архитектуры для задач реального времени, в том числе на устройствах с ограниченными вычислительными ресурсами.

**Ключевые слова:** семантическая сегментация, нейронная сеть, разметка, взлетно-посадочная полоса

**Для цитирования:** Музалевский А. Р. Семантическая сегментация разметки взлетно-посадочной полосы с использованием нейронных сетей // Изв. СПбГЭТУ «ЛЭТИ». 2025. Т. 18, № 6. С. 77–85. doi: 10.32603/2071-8985-2025-18-6-77-85.

Original article

## Runway Lane Marking Semantic Segmentation Using Neural Networks

A. R. Muzalevskii

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia

muzal2010@yandex.ru

**Abstract.** Considers the use of a convolutional neural network to solve the problem of semantic segmentation of horizontal runway lane markings based on camera data. This task is of great practical importance for improving the safety and autonomy of aircraft during landing and taxiing. To train and validate the models, a specialized data set was formed including a variety of runway images obtained from open sources and marked up manually. The article compares two architectures of convolutional neural networks – U-Net and YOLO – in terms of segmentation accuracy, inference speed, and resistance to changes in lighting conditions, weather factors, and visual noise. The applicability of each architecture for real-time tasks including on devices with limited computing resources is evaluated.

**Keywords:** semantic segmentation, neural network, lane marking, runway

**For citation:** Muzalevskii A. R. Runway Lane Marking Semantic Segmentation Using Neural Networks // LETI Transactions on Electrical Engineering & Computer Science. 2025. Vol. 18, no. 6. P. 77–85. doi: 10.32603/2071-8985-2025-18-6-77-85.

**Введение.** Семантическая сегментация в системах автономного вождения необходима для распознавания дорожного полотна, разметки, знаков, транспортных средств и препятствий. Получаемая информация используется при анализе обстановки и принятии решения беспилотным транспортным средством. Задачей алгоритмов семантической сегментации служит разделение изображения на значимые части и отнесение каждого пикселя входного изображения к определенному классу [1].

В данной статье рассматриваются вопросы разработки базовой модели для семантической сегментации линий горизонтальной разметки на взлетно-посадочной полосе (ВПП), предназначенной для использования в беспилотном измерителе коэффициента сцепления [2]. Модель обучена на специальной выборке данных, созданной на базе открытых источников.

**Обзор работ в области семантической сегментации.** В большинстве случаев задача семантической сегментации решается для дорожной разметки, которая отличается от разметки взлетно-посадочной полосы размерами и назначением. Это отличие требует создания специального набора данных с разметкой ВПП при общности методов и подходов решения задачи сегментации.

*Методы глубокого обучения.* В [3] приведен обзор технологий в области семантической сегментации с использованием глубокого обучения, в частности с использованием обучения со слабой разметкой для решения проблемы трудоемкости разметки данных для обучения сегментационных моделей. Кроме подробного обзора, в статье также формулируются нерешенные задачи в данной области. В [4] предложен метод сегментации по детекции. В нем этап предобработки включает обрезку кадра с использованием точки схода, после чего выполняется нейросетевая детекция разметки, а обнаруженные области передаются на этап аналитической сегментации. Несмотря на сложную архитектуру, алгоритм работает на частоте 24 Гц на встраиваемом компьютере. В [5] для обнаружения разметки используется архитектура ResNet-34, дополненная полносвязными слоями и слоем, ответственным за преобразование карты признаков в вид с высоты птичьего полета. Использование перспективных преобразований позволяет обнаруживать разметку с точностью до 95 % на расстоянии до 30 м. В [6] представлена архитектура ERFNet, в которой тра-

диционный для архитектуры ResNet двухмерный фильтр заменен на несколько последовательных одномерных фильтров, что повысило частоту работы сети до 41 Гц на наборе данных Cityscapes при точности сегментации до 95 %. В [7] описана комплексная система для составления цифровых карт местности высокого разрешения на основе данных камеры. На первом этапе дорожная разметка сегментируется при помощи перцептрона. Затем из перепроецированных в вид с высоты птичьего полета сегментационных масок извлекаются признаки линий разметки, которые используются на этапе одновременной локализации и построения карты вместе с данными одометрии, что позволяет получить цифровую карту дорог в высоком разрешении. Несмотря на общую точность сегментации до 95 %, используемые методы ресурсозатратны, а в статье не приводятся данные о скорости работы алгоритма, что не позволяет оценить применимость такого подхода для беспилотного движения. В [8] описана архитектура LaneNet, в которой в обнаружении разметки задействованы две нейронные сети. Первая сеть формирует список кандидатов в границы линий разметки, затем этот список границ передается во вторую сеть, отвечающую за обнаружение линий разметки. Обе сети построены на архитектуре трансформеров и оптимизированы под выполнение конкретной операции, что снижает вычислительные затраты. Алгоритм работает на частоте 250 Гц при точности определения разметки 95 %, что позволяет использовать его в беспилотных транспортных средствах. Авторы также предлагают передавать список кандидатов в границы линий в сеть для сегментации разметки, что уменьшает объем данных, обрабатываемый сегментационной сетью и служит повышению скорости работы.

Специальная модель для сегментации SAM2 (Segment Anything Model 2) предназначена для сегментации ранее детектированных объектов [9]. Она показывает отличные результаты при сегментации объектов на видео и на изображениях, но более требовательна к вычислительным ресурсам, чем сети на основе U-Net и YOLO (последняя работает в 1000 раз быстрее [10]), поэтому не может быть встроена в беспилотный измеритель.

**Описание набора данных для обучения.** Задача распознавания разметки взлетно-посадочной полосы была сведена к задаче семантической сегментации.

В ходе анализа существующих решений оказалось, что большинство работ используют кадры, полученные в симуляторе, или спутниковые снимки, что не подходит для текущей задачи, поскольку модель используется беспилотным измерителем коэффициента сцепления при движении по взлетно-посадочной полосе, поэтому необходимо было подготовить собственный набор данных [11]–[14].

Исходный набор данных состоит из шести видеозаписей, снятых из кабины самолета во время взлета и посадки. В качестве целевых классов были выбраны: «gunway» – взлетно-посадочная полоса, «solid\_white» – сплошная белая линия, «break\_white» – прерывистая белая линия. Разметка данных осуществлялась в программе с открытым исходным кодом CVAT. Итоговый набор данных состоял из 7514 изображений разных размеров. Кадры видеозаписей обладают рядом особенностей, усложняющих процесс сегментации: содержат субтитры, между кадрами бывает резкая смена ракурса, а границы объектов размыты из-за тряски. Кроме того, из-за перспективного искажения кадра линии разметки и полотно ВПП уменьшаются при приближении к горизонту, что снижает точность определения удаленных объектов и затрудняет разметку данных, что, в свою очередь, может снизить метрики качества модели.

Весь объем данных был разделен на три выборки: обучающая (2956 кадров, или 40 %), валидационная (1732 кадра, или 23 %), тестовая (2826 кадров, или 37 %). При разделении выборок во избежание утечек информации, кадры из одного видео были изолированы. Таким образом, в обучающей выборке находилось 4 видео, в валидационной и в тестовой выборках – по одному.

Чтобы повысить устойчивость модели к изменениям входных данных, использовалась методика увеличения объема данных для обучения и их разнообразия за счет различных преобразований исходных изображений (аффинные преобразования, добавление шумов и преобразования параметров цвета).

На рис. 1, *a* показан исходный кадр, а на рис. 1, *б* – его целевая маска. На маске представлены: 1 – «solid\_white», 2 – «gunway», 3 – «break\_white».

На вход нейронной сети подавалось RGB-изображение, разбитое на блоки по  $1024 \times 1024$  пикселей. Общее количество уникальных блоков составило: 11 304 – в тестовой, 6928 – в валидационной, 11 222 – в обучающей выборках.

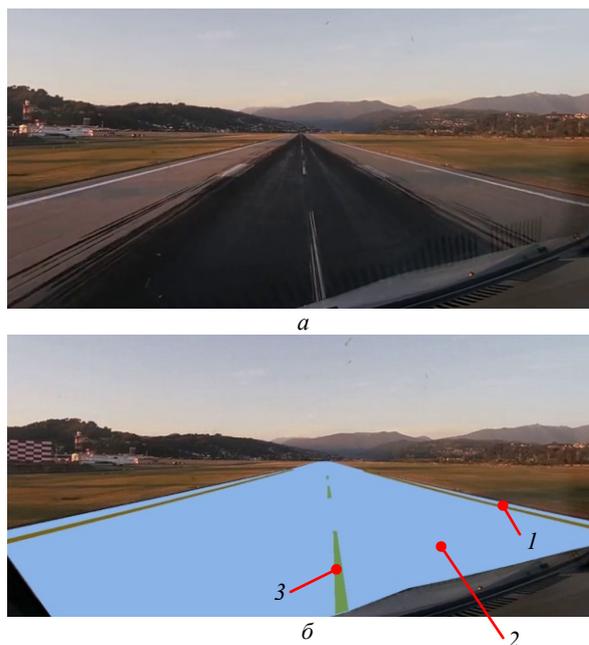


Рис. 1. Пример исходного кадра (*a*).  
Пример кадра с наложенной маской (*б*).  
Fig. 1. Original frame example (*a*).  
Ground truth mask example (*б*)

Мажорным классом служит «gunway», площадь масок которого составляет 95 % от всех размеченных масок. Класс линий разметки имеет существенно меньшую долю: «solid\_white» – 2.8 %, «break\_white» – 2.2 %. Для уменьшения влияния дисбаланса данных при расчете функции потерь используются весовые коэффициенты.

**Результаты обучения сети на основе архитектуры U-Net.** В статье использована архитектура сверточной нейронной сети U-Net [15] с ResNet34 [16]. Архитектура U-Net представляет собой модифицированную полносвязную нейронную сеть, в которой есть две важные части – энкодер и декодер (рис. 2). Каждый блок – это карта признаков, количество признаков в которой указано над блоком, а сбоку – линейные размеры блока. В энкодере исходное изображение проходит через несколько операций понижения дискретизации с выделением признаков на каждом этапе (операции conv  $3 \times 3$ , ReLU и max pool  $2 \times 2$ ), а в декодере происходят увеличение разрешения и конкатенация с обрезанной картой признаков, полученной в энкодере (операции up conv  $2 \times 2$  и crop). Всего сеть содержит 23 сверточных слоя.

Нейронная сеть обучалась в течение ста эпох с использованием видеокарты Nvidia 3090, а для визуализации процесса обучения использовался ClearML. В качестве функции потерь использовалась перекрестная энтропия, а оптимизатором стал метод адаптивной оценки моментов. На

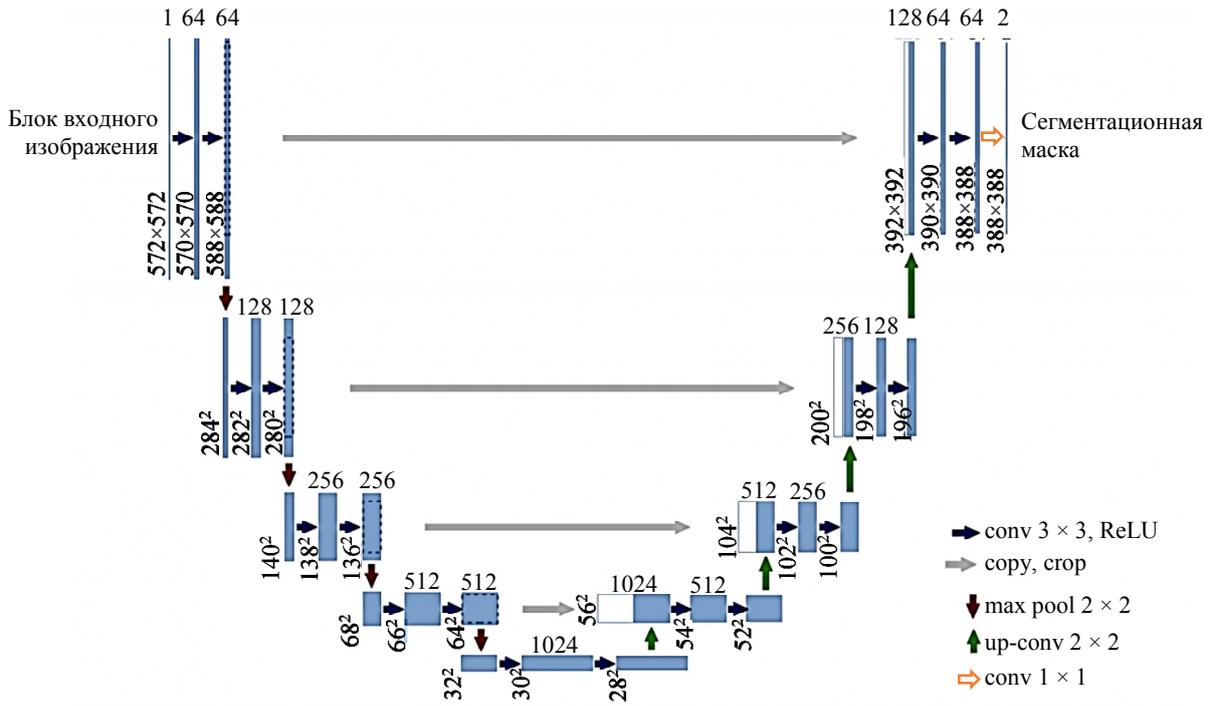


Рис. 2. Архитектура сети U-Net  
Fig. 2. U-Net architecture

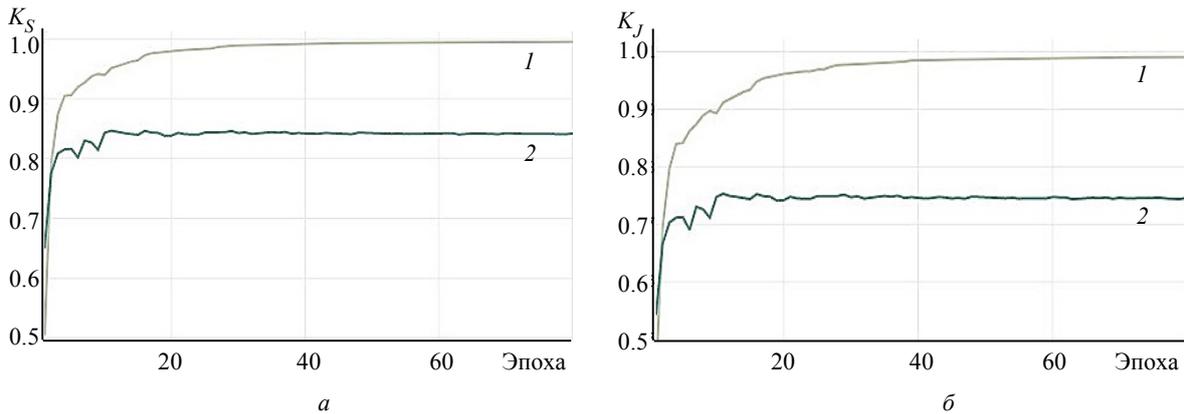


Рис. 3. Графики коэффициентов Сёрнсена (а) и Жаккара (б)  
Fig. 3. Dice macro graph (a). IoU macro graph (б)

рис. 3, а, б представлены графики обучения (кривая 1) и валидации (2) нейронной сети. По графикам видно, что модель стремится к переобучению и начиная с двадцатой эпохи выходит на плато на валидационной выборке.

В наборе данных наблюдается как дисбаланс классов – сплошная линия разметки появляется чаще прерывистых линий, так и дисбаланс размеров – взлетно-посадочная полоса занимает наибольшую площадь. Поэтому важно показать не только усредненные показатели качества, но и метрики по каждому классу. В табл. 1 представлены две метрики качества работы модели: коэффициент Жаккара  $K_J \in [0; 1]$  и коэффициент Сёрнсена  $K_S \in [0; 1]$ .

Табл. 1. Метрики качества работы модели  
Tab. 1. Model metrics

Целевой класс	Коэффициент	
	$K_J$	$K_S$
background	0.986	0.993
«runway»	0.760	0.852
«solid_white»	0.470	0.632
«break_white»	0.185	0.288
<b>micro</b>	0.970	0.984
<b>macro</b>	0.601	0.691

Метрики для мажорного класса «runway» удовлетворительные ( $\geq 0.75$ ), но метрики для классов линий разметки «solid\_white» и «break\_white» показывают низкое качество работы обученной модели ( $< 0.5$  за исключением  $K_S$  для «solid\_white»). Однако необходимо также ви-

зуально оценить результаты работы модели. На рис. 4 представлены результаты успешной сегментации линий разметки и полотна ВПП в виде исходного изображения с наложенной маской. На рис. 4, а модель ошиблась и выделила лишний участок прерывистой линии, а на рис. 4, б – лишний участок полотна ВПП. Но данные ошибки не мешают в определении точки схода линий разметки.

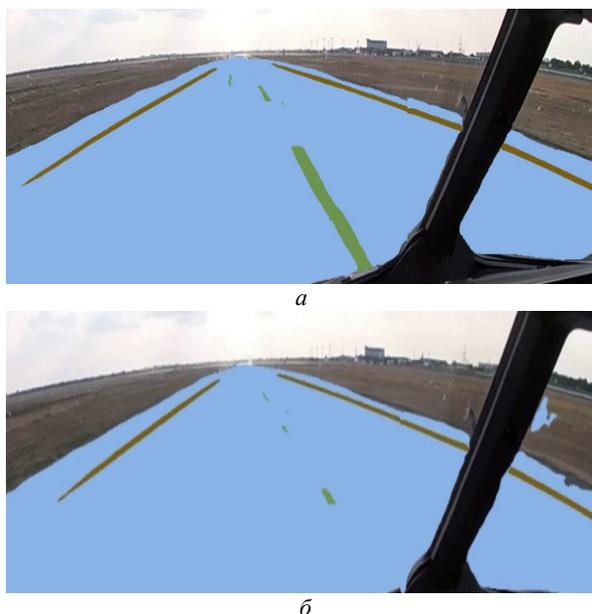


Рис. 4. Примеры кадров, на которых модель успешно определила все целевые линии разметки  
Fig. 4. Frames showing successful segmentation

На рис. 5, б представлены результаты неудовлетворительной работы модели на основе архитектуры U-Net в сложных условиях (рис. 5, а). Тень от самолета, как и множественные следы торможения на полотне ВПП не позволяют сегментировать прерывистую линию и само полотно ВПП.

Метрики и результаты работы показывают, что низкое качество взлетно-посадочной полосы, следы старой разметки и сложные погодные условия оказывают негативное влияние на качество работы модели. Для повышения качества сегментации необходимо увеличить обучающую выборку, что требует внедрения специальной нейросети для автоматической разметки изображений (например, SAM2).

Таким образом, сеть на основе архитектуры U-Net требует большого разнообразия данных для обучения, но сегментирует объекты с высокой точностью.

Обученная модель не справляется с задачей сегментирования разметки в кадре. Стремление модели к переобучению можно объяснить высокой сложностью исходных данных и их низким качеством (тряска, шум, низкое разрешение). Влияние неравномерности распределения целевых классов в обучающем наборе незначительно при использовании весовых коэффициентов.

**Результаты обучения сетей на основе архитектуры YOLOv8.** Для сравнения результатов



Рис. 5. Исходный кадр (а) и пример кадра, на котором модель не смогла корректно сегментировать объекты (б)  
Fig. 5. The original frame (a) and an example of a frame in which the model could not segment objects (b)

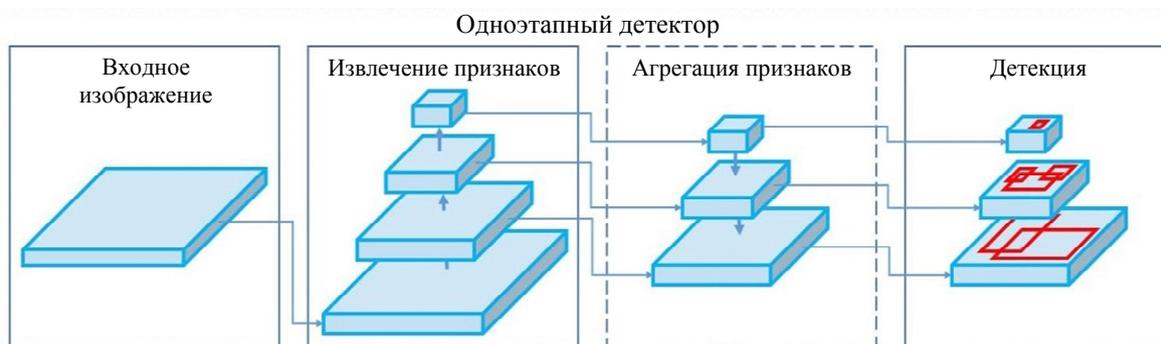


Рис. 6. Архитектура семейства сетей YOLO  
Fig. 6. YOLO architecture

была выбрана архитектура нейронной сети YOLOv8 [17]. Общая для одноэтапных детекторов архитектура нейронной сети показана на рис. 6. В ней входное изображение проходит через специализированную сеть для извлечения признаков, для YOLOv8 – это сверточная нейронная сеть CSPDarknet53, содержащая 53 слоя. Агрегация признаков происходит одновременно на нескольких слоях, что позволяет обрабатывать объекты разных размеров. Данные от каждого слоя, отвечающего за агрегацию признаков, передаются в соответствующий детектор, отвечающий за классификацию и локализацию объекта в определенной карте признаков, а затем преобразование результатов в систему координат исходного изображения.

Для исследования зависимости точности работы от количества параметров модели были выбраны начальные веса «yolov8s-seg.pt» (11.8 млн параметров), «yolov8m-seg.pt» (27.3 млн параметров), «yolov8l-seg.pt» (46.0 млн параметров), «yolov8x-seg.pt» (71.8 млн параметров). Первые три сети были обучены на кадрах двух разных размеров:  $640 \times 640$  и  $1024 \times 1024$  пикселей, а последняя – «yolov8x-seg.pt», только на кадрах размером  $640 \times 640$  пикселей. Вариация этих двух параметров позволяет оценить их влияние на точность и качество сегментации.

Таким образом, всего были обучены семь нейронных сетей на архитектуре YOLOv8.

Набор данных был расширен до 11 097 изображений, что позволило сформировать сбалансированные выборки, не внося утечек данных. Обучающая выборка содержит 80 % изображений, а валидационная и тестовая – по 10 %.

Метрики качества работы моделей YOLOv8 показаны в табл. 2 и 3.

Анализ метрик показывает, что рост количества параметров модели и размера кадра на этапе обучения ведет к увеличению метрик качества. Для получения лучшего результата необходимо использовать самую сложную модель из доступных и обучать ее на наибольшем кадре для лучшего обобщения признаков. Для более детального исследования зависимости качества от каждого параметра необходимо увеличить доступные вычислительные мощности.

Также, согласно метрикам, модель yolov8l ( $1024 \times 1024$ ) – лучшая из обученных. Однако для полноценного анализа качества работы моделей необходимо визуально оценить результаты сегментации (рис. 7).

Модель yolov8l ( $1024 \times 1024$ ) успешно обнаружила линии разметки на ВПП и определила полотно ВПП и не совершила ложных срабатываний на кадрах с дорожной разметкой, что позволяет считать ее лучшей из представленных.

**Заключение.** Обученная модель успешно справляется с задачей сегментирования разметки в кадре и может быть встроена в автономное транспортное средство, поскольку предъявляет мягкие требования к вычислительным ресурсам.

Влияние неравномерности распределения целевых классов в обучающем наборе незначительно при использовании весовых коэффициентов.

Поскольку модель показала себя удовлетворительно, в будущем планируется поддерживать ее и развивать. Для уточнения масок сегментации и повышения устойчивости модели необходимо

Табл. 2. Метрики mAP50 моделей на архитектуре YOLOv8  
Tab. 2. YOLOv8 based models metrics mAP50

Целевой класс	Модель						
	yolov8s, $640 \times 640$	yolov8m, $640 \times 640$	yolov8l, $640 \times 640$	yolov8x, $640 \times 640$	yolov8s, $1024 \times 1024$	yolov8m, $1024 \times 1024$	yolov8l, $1024 \times 1024$
all	0.989	0.911	0.852	0.921	0.937	0.93	0.954
«solid_white»	0.986	0.984	0.979	0.987	0.990	0.980	0.985
«break_white»	0.768	0.773	0.602	0.796	0.846	0.843	0.893
«runway»	0.973	0.975	0.973	0.980	0.975	0.968	0.983

Табл. 3. Метрики mAP50-95 моделей на архитектуре YOLOv8  
Tab. 3. YOLOv8 based models metrics mAP50-95

Целевой класс	Модель						
	yolov8s, $640 \times 640$	yolov8m, $640 \times 640$	yolov8l, $640 \times 640$	yolov8x, $640 \times 640$	yolov8s, $1024 \times 1024$	yolov8m, $1024 \times 1024$	yolov8l, $1024 \times 1024$
all	0.718	0.749	0.581	0.773	0.739	0.753	0.792
«solid_white»	0.702	0.754	0.551	0.783	0.748	0.805	0.766
«break_white»	0.539	0.581	0.387	0.615	0.573	0.619	0.692
«runway»	0.912	0.913	0.805	0.922	0.895	0.835	0.917

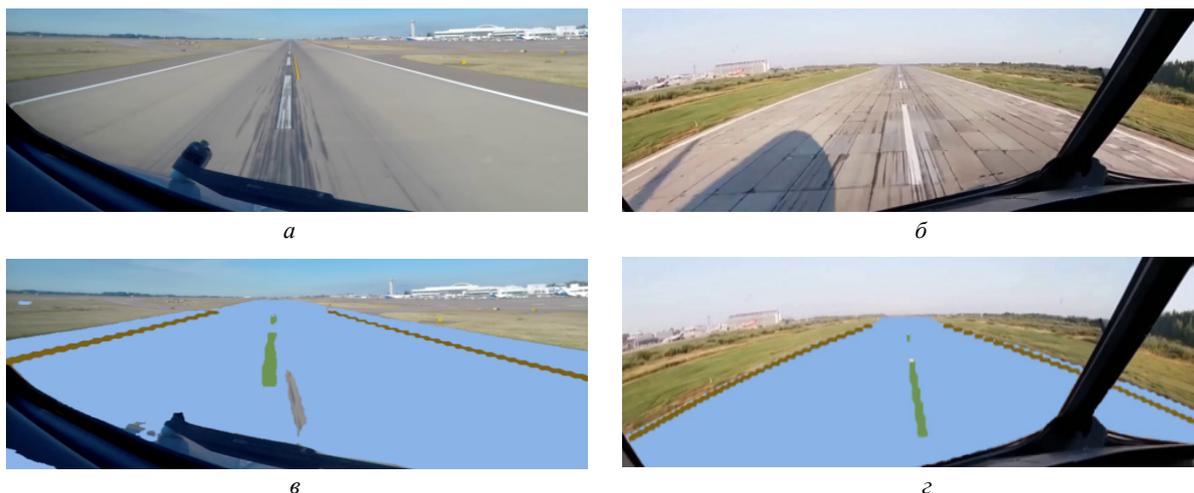


Рис. 7. Исходные кадры (а, б) и примеры корректной работы модели (в, з)  
 Fig. 7. The original frames (a, b) and an examples of a successful model prediction (v, z)

увеличить объем и разнообразие данных для обучения, что потребует внедрения нейронной сети для сегментации видео SAM2 в процесс подготовки данных. Переход на более мощное аппаратное обеспечение при обучении сети позволит увеличить размер кадра в процессе обучения, что позволит обрабатывать более крупные области изобра-

жения и повысит обобщающую способность модели. Добавление нормализации значений пикселей при обучении сети повышает скорость схождения во время обучения и положительно влияет на быстроедействие, которое можно дополнительно повысить применением квантования и обрезки.

#### Список литературы

1. Real-time semantic segmentation for autonomous driving: A review of CNNs, Transformers, and Beyond / M. A. M. Elhassan, Ch. Zhou, A. Khan, A. Benabid, A. B. M. Adam, A. Mehmood, N. Wambugu // J. of King Saud University – Comp. and Inform. Sci. 2024. Vol. 36, no. 10. Art. 102226. doi: 10.1016/j.jksuci.2024.102226.
2. Беспилотный измеритель коэффициента сцепления взлетно-посадочных полос / А. Р. Музалевский, Е. В. Друян, М. М. Копычев, В. В. Путов, Т. Л. Русяева, М. А. Чернышев // Изв. СПбГЭТУ «ЛЭТИ». 2022. Т. 15, № 7. С. 73–81. doi: 10.32603/2071-8985-2022-15-7-73-81.
3. Review the state-of-the-art technologies of semantic segmentation based on deep learning / Y. Mo, Y. Wu, X. Yang, F. Liu, Y. Liao // Neurocomputing. 2022. Vol. 493. P. 626–646. doi: 10.1016/j.neucom.2022.01.005.
4. Road marking segmentation based on siamese attention module and maximum stable external region / W. Zhang, Z. Mi, Y. Zheng, Q. Gao, W. Li // IEEE Access. 2019. Vol. 7. P. 143710–143720. doi: 10.1109/ACCESS.2019.2944993.
5. Detecting lane and road markings at a distance with perspective transformer layers / Z. Yu, X. Ren, Y. Huang, W. Tian, J. Zhao // 2020 IEEE 23<sup>rd</sup> Intern. Conf. on Intelligent Transportation Syst. (ITSC). Rhodes, Greece: IEEE, 2020. P. 1–7. doi: 10.1109/ITSC45102.2020.9294383.
6. ERFNet: Efficient Residual Factorized ConvNet for real-time semantic segmentation / E. Romera, J. M. Álvarez, L. M. Bergasa, R. Arroyo // IEEE Transactions on Intelligent Transportation Syst. 2018. Vol. 19, no. 1. P. 263–272. doi: 10.1109/TITS.2017.2750080.
7. Road lane semantic segmentation for high definition map / W. Jang, J. An, S. Lee, M. Cho, M. Sun, E. Kim // 2018 IEEE Intelligent Vehicles Symp. (IV). Changshu, China: IEEE, 2018. P. 1001–1006. doi: 10.1109/IVS.2018.8500661.
8. Wang Z., Ren W., Qiu Q. LaneNet: Real-Time Lane detection networks for autonomous driving // ArXiv. 2018. P. 1–9. doi: 10.48550/arXiv.1807.01726.
9. SAM 2: Segment Anything in images and videos / N. Ravi, V. Gabeur, Y. Hu, R. Hu, C. Ryali, T. Ma, H. Khedr, R. Rädle, C. Rolland, L. Gustafson, E. Mintun, J. Pan, K. V. Alwala, N. Carion, C. Wu, R. Girshick, P. Dollár, Ch. Feichtenhofer // ArXiv. 2024. P. 1–42. doi: 10.48550/arXiv.2408.00714.
10. SAM 2 comparison vs YOLOv8. URL: <https://docs.ultralytics.com/models/sam-2/#sam-2-comparison-vs-yolov8> (дата обращения: 14.11.2024).
11. BARS: a benchmark for airport runway segmentation / W. Chen, Z. Zhang, L. Yu, Y. Tai // Applied Intelligence. 2023. Vol. 53(17). P. 20485–20498. doi: 10.1007/s10489-023-04586-5.
12. Research on crack detection method of airport runway based on twice-threshold segmentation / L. Peng, W. Chao, L. Shuangmiao, F. Baocai // 2015 Fifth Intern. Conf. on Instrumentation and Measurement, Comp., Commun. and Control (IMCCC). Qinhuangdao, China: IEEE, 2015. P. 1716–1720. doi: 10.1109/IMCCC.2015.364.

13. Ding W., Wu J. An airport knowledge-based method for accurate change analysis of airport runways in VHR remote sensing images // *Remote Sensing*. 2020. Vol. 12, no. 19. Art. 3163. P. 1–22. doi: 10.3390/rs12193163.
14. Zhang L., Cheng Y., Zhai Zh. Real-time accurate runway detection based on airborne multi-sensors fusion // *Defence Sci. J.* 2017. Vol. 67, no. 5. P. 542–550. doi: 10.14429/dsj.67.10439.
15. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for biomedical image segmentation // *ArXiv*. 2015. P. 234–241. doi: 10.48550/arXiv.1505.04597.

16. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun. // 2016 IEEE Conf. on Comp. Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016. P. 770–778. doi: 10.1109/CVPR.2016.90.
17. Bochkovskiy A., Wang C. Y., Liao H.-Y. M. Yolov4: Optimal speed and accuracy of object detection. doi: 10.48550/arXiv:2004.10934. URL: [https://www.researchgate.net/publication/340883401\\_YOLOv4\\_Optimal\\_Speed\\_and\\_Accuracy\\_of\\_Object\\_Detection](https://www.researchgate.net/publication/340883401_YOLOv4_Optimal_Speed_and_Accuracy_of_Object_Detection) (дата обращения: 12.02.25).

#### Информация об авторе

**Музалевский Александр Раймундович** – ассистент кафедры систем автоматического управления СПбГЭТУ «ЛЭТИ».

E-mail: muzal2010@yandex.ru

#### References

1. Real-time semantic segmentation for autonomous driving: A review of CNNs, Transformers, and Beyond / M. A. M. Elhassan, Ch. Zhou, A. Khan, A. Benabid, A. B. M. Adam, A. Mehmood, N. Wambugu // *J. of King Saud University – Comp. and Inform. Sci.* 2024. Vol. 36, no. 10. Art. 102226. doi: 10.1016/j.jksuci.2024.102226.
2. Bepilotnyj izmeritel' kojefficienta scepjenija vzletno-posadochnyh polos / A. R. Muzalevskij, E. V. Drujan, M. M. Kopychev, V. V. Putov, T. L. Rusjaeva, M. A. Chernyshev // *Izv. SPbGJeTU «LjeTI»*. 2022. T. 15, № 7. S. 73–81. doi: 10.32603/2071-8985-2022-15-7-73-81. (In Russ.).
3. Review the state-of-the-art technologies of semantic segmentation based on deep learning / Y. Mo, Y. Wu, X. Yang, F. Liu, Y. Liao // *Neurocomputing*. 2022. Vol. 493. P. 626–646. doi: 10.1016/j.neucom.2022.01.005.
4. Road marking segmentation based on siamese attention module and maximum stable external region / W. Zhang, Z. Mi, Y. Zheng, Q. Gao, W. Li // *IEEE Access*. 2019. Vol. 7. P. 143710–143720. doi: 10.1109/ACCESS.2019.2944993.
5. Detecting lane and road markings at a distance with perspective transformer layers / Z. Yu, X. Ren, Y. Huang, W. Tian, J. Zhao // 2020 IEEE 23<sup>rd</sup> Intern. Conf. on Intelligent Transportation Syst. (ITSC). Rhodes, Greece: IEEE, 2020. P. 1–7. doi: 10.1109/ITSC45102.2020.9294383.
6. ERFNet: Efficient Residual Factorized ConvNet for real-time semantic segmentation / E. Romera, J. M. Álvarez, L. M. Bergasa, R. Arroyo // *IEEE Transactions on Intelligent Transportation Syst.* 2018. Vol. 19, no. 1. P. 263–272. doi: 10.1109/TITS.2017.2750080.
7. Road lane semantic segmentation for high definition map / W. Jang, J. An, S. Lee, M. Cho, M. Sun, E. Kim // 2018 IEEE Intelligent Vehicles Symp. (IV). Changshu, China: IEEE, 2018. P. 1001–1006. doi: 10.1109/IVS.2018.8500661.
8. Wang Z., Ren W., Qiu Q. LaneNet: Real-Time Lane detection networks for autonomous driving // *ArXiv*. 2018. P. 1–9. doi: 10.48550/arXiv.1807.01726.

9. SAM 2: Segment Anything in images and videos / N. Ravi, V. Gabeur, Y. Hu, R. Hu, C. Ryali, T. Ma, H. Khedr, R. Rädle, C. Rolland, L. Gustafson, E. Mintun, J. Pan, K. V. Alwala, N. Carion, C. Wu, R. Girshick, P. Dollár, Ch. Feichtenhofer // *ArXiv*. 2024. P. 1–42. doi: 10.48550/arXiv.2408.00714.
10. SAM 2 comparison vs YOLOv8. URL: <https://docs.ultralytics.com/models/sam-2/#sam-2-comparison-vs-yolov8> (data obrashhenija: 14.11.2024).
11. BARS: a benchmark for airport runway segmentation / W. Chen, Z. Zhang, L. Yu, Y. Tai // *Appl. Intelligence*. 2023. Vol. 53(17). P. 20485–20498. doi: 10.1007/s10489-023-04586-5.
12. Research on crack detection method of airport runway based on twice-threshold segmentation / L. Peng, W. Chao, L. Shuangmiao, F. Baocai // 2015 Fifth Intern. Conf. on Instrumentation and Measurement, Comp., Commun. and Control (IMCCC). Qinquangdao, China: IEEE, 2015. P. 1716–1720. doi: 10.1109/IMCCC.2015.364.
13. Ding W., Wu J. An Airport Knowledge-Based Method for accurate change analysis of airport runways in VHR remote sensing images // *Remote Sensing*. 2020. Vol. 12, no. 19. Art. 3163. P. 1–22. doi: 10.3390/rs12193163.
14. Zhang L., Cheng Y., Zhai Zh. Real-time accurate runway detection based on airborne multi-sensors fusion // *Defence Sci. J.* 2017. Vol. 67, no. 5. P. 542–550. doi: 10.14429/dsj.67.10439.
15. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // *ArXiv*. 2015. P. 234–241. doi: 10.48550/arXiv.1505.04597.
16. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun. // 2016 IEEE Conf. on Comp. Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016. P. 770–778. doi: 10.1109/CVPR.2016.90.

17. Bochkovskiy A., Wang C. Y., Liao H.-Y. M. YOLOv4: Optimal speed and accuracy of object detection. doi: 10.48550/arXiv:2004.10934. URL: [https://www.researchgate.net/publication/340883401\\_YOLOv4\\_Optimal\\_Speed\\_and\\_Accuracy\\_of\\_Object\\_Detection](https://www.researchgate.net/publication/340883401_YOLOv4_Optimal_Speed_and_Accuracy_of_Object_Detection) (data obrashhenija: 12.02.25).

---

#### Information about the author

**Alexander R. Muzalevskii** – Assistant of the Department of Automatic Control Systems, Saint Petersburg Electrotechnical University.

E-mail: [muzal2010@yandex.ru](mailto:muzal2010@yandex.ru)

Статья поступила в редакцию 19.03.2025; принята к публикации после рецензирования 23.04.2025; опубликована онлайн 30.06.2025.

Submitted 19.03.2025; accepted 23.04.2025; published online 30.06.2025.

---