

Научная статья

УДК 004.932.2

DOI: 10.17072/1993-0550-2025-2-65-87

<https://elibrary.ru/sijpkl>



Модели сегментации сердечных артерий по коронарографическим снимкам

Владислав Антонович Бочкарев¹, Александр Андреевич Усынин², Александр Денисович Осипов³, Михаил Русланович Аухадиев⁴, Роман Владиславович Шаров⁵, Марина Александровна Барулина⁶

^{1,2,3,4,5,6} Пермский государственный национальный исследовательский университет,
г. Пермь, Россия

¹pikova98@gmail.com

²alexandrusynin2306@gmail.com

³alexisipov03@yandex.com

⁴tyver9@gmail.com

⁵roma752275@mail.ru

⁶mab@psu.ru

Аннотация. Сердечно-сосудистые заболевания продолжают лидировать среди причин смертности. Снизить смертность и повысить точность диагностики можно с помощью разработки решений на основе искусственного интеллекта. При этом важнейшей из задач является сегментация сердечных артерий. Точная сегментация коронарных сосудов на ангиографических снимках критически важна для выявления стеноза и планирования интервенционных процедур. Однако автоматизированные методы сегментации сталкиваются с рядом проблем, связанных с затруднением распознания сердечных артерий: неравномерное распределение контрастного вещества, артефакты движения, наложение теней от анатомических структур. В данной работе представлена модель сегментации сосудов на основе модифицированной архитектуры U-Net, включающей residual-блоки и механизмы внимания (SCSE) с предварительным обучением энкодера на искусственном датасете для выделения сосудистых признаков. Особое внимание уделено устойчивости модели к шумам – ключевой проблеме ангиографических данных, с которой не справляются многие существующие методы. Модель обучалась на смешанном наборе данных из 1285 двумерных коронарографических снимках, аннотированных экспертами. Предложенный подход достиг значения IoU 0.54 и F1-score 0.79 на тестовой выборке, демонстрируя устойчивость к шуму и артефактам. Дополнительная постобработка с адаптивной фильтрацией улучшила качество бинарных масок, устранив ложные срабатывания от катетеров и металлических объектов. Внешняя оценка на 50 изображениях из независимого клинического набора показала IoU 0.50 и F1-score 0.75, что превосходит базовые методы сегментации, такие как классическая U-Net (IoU 0.42). Результаты подчеркивают эффективность предложенной модели для сегментации сосудов в условиях реальных ангиограмм, а также демонстрируют потенциал подхода как основы для последующей 3D-



Эта работа © 2025 Бочкарев В. А., Усынин А. А., Осипов А. Д., Аухадиев М. Р., Шаров Р.В., Барулина М. А. распространяется по лицензии CC BY 4.0. Чтобы просмотреть копию этой лицензии, посетите <https://creativecommons.org/licenses/by/4.0/>.

реконструкции сосудистой сети, что может улучшить диагностику и планирование лечения стеноза коронарных артерий.

Ключевые слова: сердечно-сосудистые заболевания; коронарография; сегментация коронарных сосудов; предобработка изображений; U-Net; механизмы внимания; глубокое обучение

Для цитирования: Бочкирев В. А., Усынин А. А., Осипов А. Д., Аухадиев М. Р., Шаров Р. В., Барулина М. А. Модели сегментации сердечных артерий по коронарографическим снимкам // Вестник Пермского университета. Математика. Механика. Информатика. 2025. Вып. 2(69). С. 65–88. DOI: 10.17072/1993-0550-2025-2-65-87. <https://elibrary.ru/sijpk1>

Статья поступила в редакцию 16.04.2025; одобрена после рецензирования 25.05.2025; принята к публикации 09.07.2025.

Research article

Models of Cardiac Artery Segmentation From Coronary Angiographic Images

Vladislav A. Bochkarev¹, Alexander A. Usynin², Alexander D. Osipov³, Mikhail R. Aukhadiev⁴, Roman V. Sharov⁵, Marina A. Barulina⁶

^{1,2,3,4,5,6} Perm State University, Perm, Russia

¹pikova98@gmail.com

²alexandrusynin2306@gmail.com

³alexisipov03@yandex.com

⁴tyver9@gmail.com

⁵roma752275@mail.ru

⁶mab@psu.ru

Abstract. Cardiovascular diseases remain the leading cause of death. Mortality can be reduced and diagnostic accuracy can be improved by developing artificial intelligence-based solutions. The most important task here is segmentation of cardiac arteries. Accurate segmentation of coronary vessels on angiographic images is critical for detecting stenosis and planning interventional procedures. However, automated segmentation methods face a number of problems associated with difficulty in recognizing cardiac arteries: uneven distribution of contrast agent, motion artifacts, and superposition of shadows from anatomical structures. This paper presents a vessel segmentation model based on a modified U-Net architecture, including residual blocks and attention mechanisms (SCSE) with pre-training of the encoder on an artificial dataset for extracting vascular features. Particular attention is paid to the model's resistance to noise, a key problem of angiographic data that many existing methods cannot cope with. The model was trained on a mixed dataset of 1285 2D coronary angiogram images annotated by experts. The proposed approach achieved an IoU of 0.54 and an F1-score of 0.79 on the test set, demonstrating robustness to noise and artifacts. Additional post-processing with adaptive filtering improved the quality of binary masks, eliminating false positives from catheters and metal objects. External evaluation on 50 images from an independent clinical dataset showed an IoU of 0.50 and an F1-score of 0.75, which outperforms baseline segmentation methods such as the classical U-Net (IoU 0.42). The results highlight the effectiveness of the proposed model for vessel segmentation in real-world angiograms and demonstrate the potential of the approach as a basis for subsequent 3D reconstruction of the vascular network, which may improve diagnosis and treatment planning for coronary artery stenosis.

Keywords: cardiovascular diseases; coronary angiography; coronary vessel segmentation; image preprocessing; U-Net; attention mechanisms; deep learning

For citation: Bochkarev, V. A., Usynin, A. A., Osipov, A. D., Auhadiev, M. R., Sharov, R. V. and Barulina, M. A. (2025), "Models of Cardiac Artery Segmentation Based on Coronary Angiographic Images", *Bulletin of Perm University. Mathematics. Mechanics. Computer Science*, no. 2(69), p. 65–88. DOI: 10.17072/1993-0550-2025-2-65-87. <https://elibrary.ru/sijpkl>

The article was submitted 16.04.2025; approved after reviewing 25.05.2025; accepted for publication 09.07.2025.

Введение

Сердечно-сосудистые заболевания (ССЗ) являются ведущей причиной смертности и инвалидности во всем мире [1]. По данным Всемирной организации здравоохранения, только в 2021 году ССЗ унесли жизни более 20 миллионов человек, что составляет около трети всех зарегистрированных смертей на планете [2]. Среди множества патологических процессов, лежащих в основе ССЗ, особое внимание привлекает стеноз коронарных артерий – патологическое сужение сосудов, которое нарушает нормальное кровоснабжение миокарда и может стать причиной инфаркта миокарда, сердечной недостаточности и других критических осложнений [3]. Успешное лечение таких состояний во многом зависит от точной и своевременной диагностики, а также от грамотного планирования интервенционных процедур, таких как стентирование или коронарное шунтирование, что подчеркивает важность современных подходов к визуализации и анализу сосудистой сети сердца [4]. В этом контексте детальная визуализация коронарных сосудов становится незаменимым инструментом, предоставляя врачам информацию о морфологии, анатомических особенностях и функциональном состоянии сосудов, что критически важно для принятия клинических решений [5].

Исследования в области автоматической сегментации коронарных сосудов ведутся как российскими, так и зарубежными учеными. Например, ряд работ подчеркивает важность точного выделения сосудистых структур на 2D-ангиограммах как основы для построения 3D-моделей, что требует применения сложных алгоритмов обработки изображений [6]. Такие подходы приобретают особую актуальность в ситуациях, когда традиционные методы синхронизации данных, такие как использование электрокардиограммы (ЭКГ) для определения фазы сердечного цикла, недоступны в реальной клинической практике [7]. Автоматизация процессов сегментации и анализа не только сокращает время, необходимое для подготовки диагностических данных, но и повышает воспроизводимость результатов, что особенно ценно для специалистов с ограниченным опытом, таких как молодые кардиохирурги [8]. Кроме того, использование ИИ позволяет минимизировать человеческий фактор, снижая вероятность ошибок, связанных с субъективной интерпретацией изображений [9].

Для диагностики и лечения ССЗ специалисты традиционно полагаются на стандартную коронарографию – метод, который позволяет получать двумерные (2D) изображения сосудов в реальном времени. Этот подход уже давно зарекомендовал себя в клинической практике благодаря своей доступности и информативности [5]. В последние годы искусственный интеллект, и, в частности, глубокое обучение, показал высокую эффективность в анализе медицинских изображений, включая задачи сегментации сосудистых структур [8]. Одной из наиболее успешных архитектур для таких задач является U-Net – сверточная нейронная сеть, разработанная для сегментации биомедицинских изображений и демонстрирующая высокую точность в выделении сложных структур на зашумленных данных [10].

Для повышения эффективности U-Net часто модифицируется: например, добавляются residual-блоки для улучшения сходимости обучения [11], а также

механизмы внимания, такие как SCSE (Spatial and Channel Squeeze-and-Excitation), которые позволяют модели фокусироваться на наиболее значимых областях изображения [12]. Эти улучшения особенно полезны при работе с ангиографическими данными, где низкий контраст и шумы являются распространенными проблемами.

Целью данной работы является разработка и валидация метода автоматической сегментации коронарных сосудов на двумерных ангиографических снимках с использованием глубокого обучения. Предложенный подход направлен на преодоление ограничений традиционного анализа за счет применения модифицированной модели глубокого обучения, обученной на смешанном датасете, включающем реальные и синтетические данные, что обеспечивает устойчивость к вариациям качества изображений.

В качестве базовой архитектуры для построения автоматического сегментатора была выбрана архитектура U-Net, как наиболее гибкая из существующих базовых архитектур, и способная эффективно сочетать локальные, глобальные признаки через skip-связи [10], что особенно важно для сегментации объектов с тонкими границами, такими как тонкие сосуды на ангиограммах с низким контрастом.

2. Методы исследования

2.1. Наборы данных

2.1.1. Исходный набор данных (Raw)

Данные для исследования включали 36000 анонимизированных необработанных DICOM файлов, каждый DICOM содержал 30–60 изображений коронарной ангиографии, предоставленных Федеральным центром сердечно-сосудистой хирургии им. С.Г. Суханова (ФЦССХ). Эти изображения представляли собой рентгеновские ангиограммы, выполненные с использованием стандартного оборудования и контрастного вещества, введенного через катетер (рис. 1).

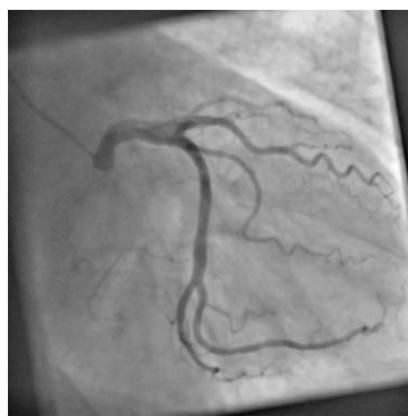


Рис. 1. Снимок коронарографии

Из-за низкого контраста не все изображения подходили для анализа, так как на таких изображениях плохая видимость сердечно-сосудистых артерий. Поэтому были взяты по три кадра из середины каждого DICOM файла, когда контраст в большинстве случаев заполнил сердечные артерии. Таким образом, был сформирован датасет (Raw-датасет) из 108000 изображений.

2.1.2. Набор данных для классификатора (Good/Bad)

Для последующей фильтрации изображений был сформирован датасет "Good/Bad", включающий 500 изображений с низким качеством и 200 изображений с высоким качеством, отобранных вручную (рис. 2).

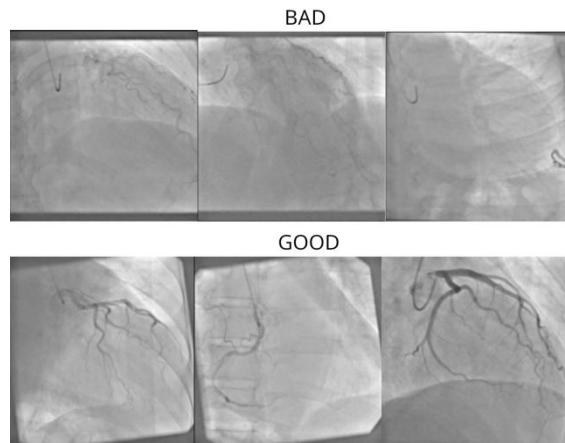


Рис. 2. Пример датасета (Good/Bad)

Критериями отнесения изображений к категории "плохих" служили: некорректная экспозиция (например, чрезмерная затемненность или пересвет), наличие выраженных артефактов (в том числе сильное размытие, обусловленное движением сердца), недостаточная визуализация контраста, а также низкая различимость сосудистой структуры. В свою очередь, к категории "хороших" относились изображения с отчетливо визуализированными артериями и выраженным контрастированием.

Данный датасет был использован для обучения модели классификации изображений на два класса на основе архитектуры ResNet-50 [11]. После завершения обучения модель была применена к полному набору изображений (108 000 снимков), по результатам чего было отобрано 14 000 снимков высокого качества, составивших итоговый RawGood-датасет.

2.1.3. Размеченный набор данных (Segmentation)

1285 изображений коронарографии из RawGood-датасета были размечены с помощью экспертов – сотрудников ФЦСХ. Разметкой являлось выделение маски, соответствующей сердечным артериям. Датасет сформирован из необработанных снимков путем разметки в программе "Label-Studio" [13], тем самым был получен Segmentation-датасет (рис. 3).

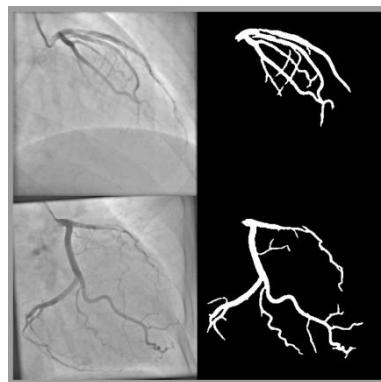


Рис. 3. Пример датасета (Segmentation)

2.1.4. Набор данных с шумами

Ключевым недостатком Segmentation-датасета является его "стерильность". В полученном наборе данных крайне мало примеров разметки зашумленных снимков, что ограничивает вариативность данных. Для решения этой проблемы был выбран метод искусственного добавления шумов, для которого был создан дополнительный датасет. При решении задачи сегментации были выделены следующие ключевые проблемы реальных данных ангиографических снимков (рис. 4).

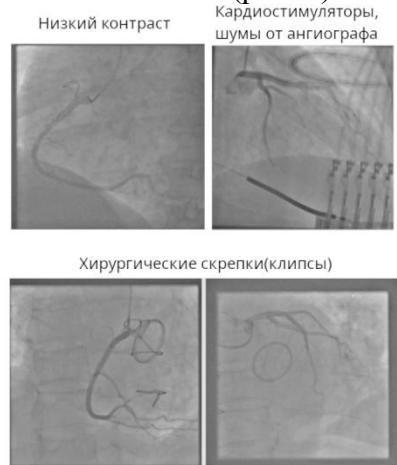


Рис. 4. Проблемные для сегментации снимки коронарографии

Первая проблема – низкий контраст. Контрастное вещество распределяется неравномерно, что приводит к слабой видимости тонких сосудов, особенно на периферии [6]. Это усложняет задачу сегментации, так как модель должна отличать сосуды от фона с минимальными визуальными подсказками. Вторая проблема – наличие таких артефактов, как:

- клапаны и скобы. Металлические объекты, такие как хирургические скобы или клапаны, создают яркие пятна, которые могут быть ошибочно приняты за сосуды;
- кардиостимуляторы. Провода и электроды кардиостимуляторов пересекают область сердца, добавляя линейные структуры, схожие с сосудами по форме;
- шумы от ангиографа. Случайные артефакты, вызванные движением пациента или оборудования, ухудшают качество изображения;
- длинный катетер. Катетер, используемый для введения контрастного вещества, часто виден на снимках как длинная изогнутая линия, которую модель может ошибочно идентифицировать как сосуд, из-за схожей интенсивности и формы [6].

Таким образом, для последующего добавления шумов был создан Noise-датасет. Он состоит из снимков, имитирующих естественные шумы, появляющиеся на типичных ангиограммах. Шумы были созданы путем копирования артефактов и искажений с реальных снимков Raw-датасета и верифицированы врачами. Был создан 31 образец уникальных шумов. Датасет состоит из 5 типов шумов (рис. 5):

1. Сердечные клапаны – (механические или биологические) протезы, представляющие собой анатомические или имплантируемые структуры, которые создают яркие тени или пятна на ангиографических снимках из-за высокой плотности материала, что может затруднять выделение сосудов.

2. Имплантируемые кардиостимуляторы – медицинские устройства с металлическими электродами и проводами, которые пересекают область сердца, формируя линейные артефакты, схожие по форме с сосудами, что приводит к проблемам при сегментации.
3. Ангиографические катетеры – гибкие трубы, используемые для введения контрастного вещества, которые отображаются на снимках как длинные изогнутые линии с интенсивностью, близкой к сосудам, что делает их частой причиной ложных срабатываний в задачах сегментации.
4. Хирургические скрепки (клипсы) – металлические фиксаторы, оставшиеся от предыдущих операций, которые проявляются на ангиограммах как темные скрюченные кривые, ошибочно принимаемые моделью за элементы сосудистой сети.
5. Шумы от ангиографа – элементы ангиографической машины, которые иногда попадают в кадр.

Цель создания данного датасета в том, чтобы в процессе обучения модели иногда добавлять шум к исходному изображению, так, чтобы модель научилась игнорировать похожие структуры (рис. 6). Было принято решение не создавать отдельный датасет с исходными снимками и шумами, а перенести процесс создания зашумленных примеров прямо в процесс предобработки данных при обучении модели.

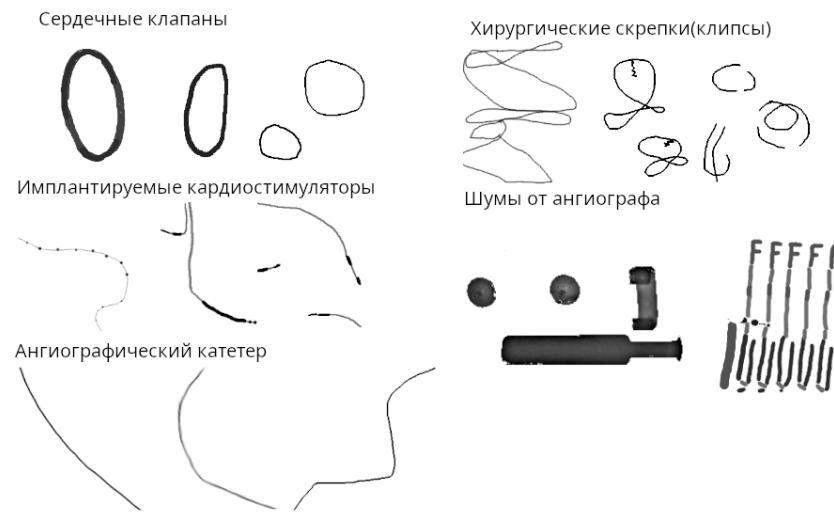


Рис. 5. Срез Noise-датасета с естественными шумами разбитыми по группам

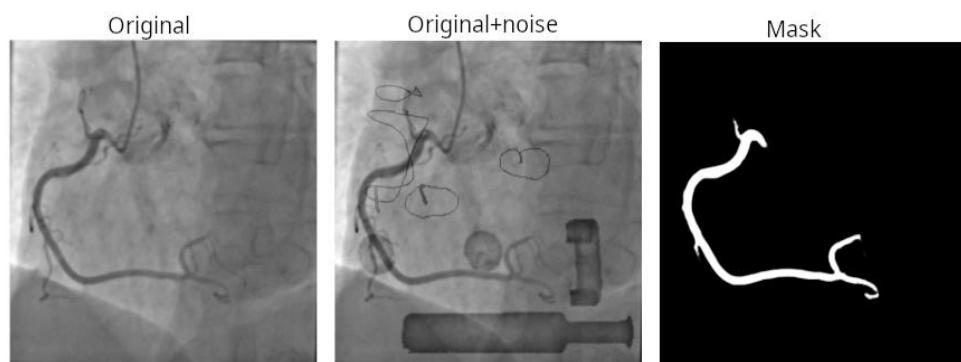


Рис. 6. Создание зашумленного примера, используя данные из (Segmentation) и (Noise) датасетов

2.1.5. Искусственные данные для предобучения (Filter)

Для повышения эффективности обучения модели сегментации и улучшения ее способности извлекать признаки сосудистых структур был разработан искусственный датасет, предназначенный для предварительного обучения (pre-training) модели сегментации на прокси-задаче [14].

Искусственный набор данных (Filter-датасет) был создан на основе (RawGood) данных. Каждое изображение подвергалось многоэтапной обработке для формирования одноканального изображения, акцентирующего внимание на сосудистые структуры. Размер каждого изображения был приведен к стандартному разрешению 512x512 пикселей, что соответствует входным требованиям модели U-Net [10]. Этапы обработки:

1. Фильтрация Mean Shift. Исходные снимки обрабатывались с использованием алгоритма Mean Shift [15], который представляет собой метод кластеризации в пространстве интенсивностей и координат. Mean Shift эффективно сглаживает шумы и однородные области фона, сохраняя при этом резкие границы объектов, такие как сосуды. Параметры фильтра (ширина окна $h_s = 16$ для пространственного измерения и $h_r = 32$ для диапазона интенсивности) были подобраны эмпирически для оптимального подавления небольших артефактов при сохранении сосудистых структур. Результат этого этапа обозначен как канал C_0 , который стал базой для последующих фильтров благодаря улучшенному соотношению сигнал/шум.
2. Выделение краев с помощью Canny. На канал C_0 применялся фильтр Canny [16], предназначенный для детекции краев. Этот алгоритм включает вычисление градиента изображения с помощью оператора Собеля [17], устранение градиентных откликов и двойное пороговое значение (низкий порог = 50, высокий порог = 150) для выделения четких границ. Фильтр Canny был выбран за его способность точно определять края сосудов даже при низком контрасте, что делает его идеальным для задач сегментации. Результат обозначен как канал C_1 , представляющий бинарную карту краев сосудов.
3. Подчеркивание изменений интенсивности с помощью Gradient Magnitude. На канал C_0 также применялся фильтр Gradient Magnitude [18], который вычисляет величину градиента интенсивности в каждом пикселе по формуле $G = \sqrt{(G_x^2 + G_y^2)}$, где G_x и G_y – горизонтальный и вертикальный градиенты, полученные с помощью оператора Собеля (ядро 3×3). Этот метод подчеркивает области с резкими изменениями яркости, что соответствует расположению сосудов на ангиограммах, особенно в зонах перехода между контрастным веществом и фоном. Результат обозначен как канал C_2 , предоставляющий непрерывную карту интенсивности градиентов.
4. Формирование изображения. Итоговое изображение создавалось путем усреднения двух каналов: C_1 (карта краев от Canny) и C_2 (градиентная карта). Таким образом, каждое изображение в датасете представляло собой тензор размером 512×512, где каждый канал подчеркивал различные аспекты сосудистых структур: границы (C_1) и изменения интенсивности (C_2) (Рис. 7). Такое представление позволяет модели обучаться на многоуровневых признаках сосудов.

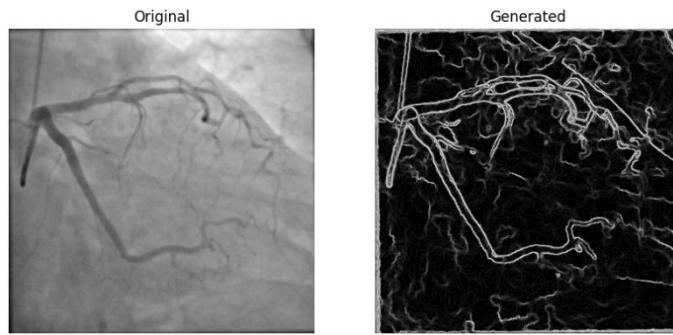


Рис. 7. Пример из сгенерированного датасета

2.2. Сегментация сосудов

На рис. 8 представлен пример ангиографического снимка с наложенной сегментационной маской, демонстрирующий, как модель должна различать сосуды на фоне шумов и артефактов. Для подготовки данных к сегментации все изображения нормализовались в диапазоне [0,1] и приводились к разрешению 512×512 пикселей. Аугментации, включая добавление искусственных шумов из Noise-датасета, позволили повысить устойчивость модели к реальным клиническим условиям.

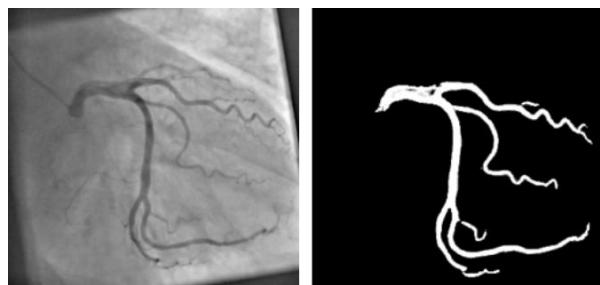


Рис. 8. Сегментация сосудов

2.2.1. Архитектура модели

Для выделения сердечных артерий была разработана новая архитектура UNet-CoroSeg, которая представляет собой комбинацию архитектур UNet [10], UNet++ [19] и DeepLabV3 [20]. Архитектура используемой UNET модели включает:

- резидуальные связи: Внедрение residual-блоков позволяет обеспечить эффективное прохождение градиентов, что стабилизирует процесс оптимизации модели и ускоряет сходимость;
- нормализация слоев: Применение батч-нормализации способствует снижению внутреннего ковариационного сдвига, что дополнительно стабилизирует обучение;
- механизмы внимания (SCSE): Модуль SCSE [12] (Concurrent Spatial and Channel Squeeze & Excitation) усиливает значимые признаки, автоматически выделяя наиболее информативные области изображения;
- расширенные свертки (dilated convolutions): использование сверток со сдвигами позволяет на последней свертке encoder блока и в skip блоке увеличить receptive поле модели без потери производительности [21];
- промежуточные свертки (интерполяция по мотивам U-Net++ [19]): Данный подход способствует лучшему распространению признаков между слоями, сохраняя при этом умеренное число параметров модели.

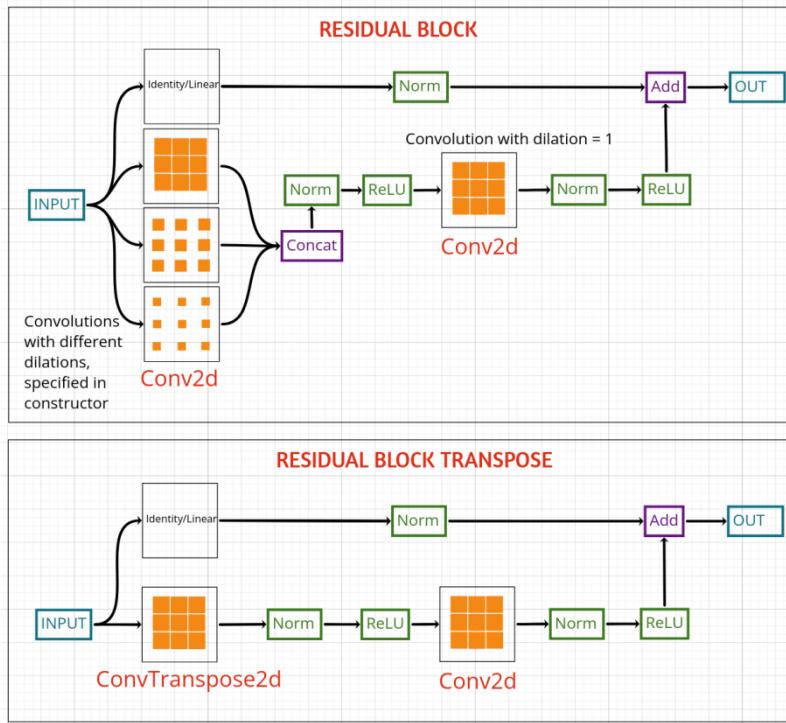


Рис. 9. Архитектура Residual Block

Данные блоки реализуют базовые операции свертки и развертывания тензоров, с изменением, размерности и количества каналов (рис. 9). Residual Block на уровне архитектуры может использовать ядра с различными сдвигами (dilation), что позволяет получить для модели более широкое рецептивное окно. Модель состоит из трех частей (рис. 10): Encoder блок, skip connector блок, decoder блок. **Encoder блок** сжимает исходное изображение, с каждым этапом уменьшая его размер, увеличивая количество каналов. Все свертки происходят с размером ядра 4, последний слой имеет dilation со сдвигами 1,3,5. **Skip connector блок** для каждого из промежуточных этапов работы блока encoder, применяет блок конволюции, внимания и dropout. Каждый residual блок промежуточной свертки имеет dilation 1,2,4. **Decoder** – производит транспонированные конволюции, увеличивает размер изображения, уменьшает каналы, и на каждом из этапов развертки соединяет результаты соответствующего этапа с skip блока. **SCSE – Concurrent Spatial and Channel Squeeze & Excitation (SCSE) module** [12], модуль внимания, который масштабирует входной тензор маской со значениями от 0 до 1, что позволяет модели обучаться фокусироваться на определенных областях. **Norm** – батч нормализация, **Dropout** – модуль отбрасывания некоторых каналов на 2д изображении. На всех участках модели dropout = 0.1.

В частности, во всех сверточных слоях модели используются ядра размером 4×4, что позволяет эффективнее охватывать локальные паттерны по сравнению с традиционными ядрами 3×3. Дополнительно, для расширения рецептивного поля модели и более глубокого анализа пространственных зависимостей, изначально применявшимися **расширенные (dilated) свертки** в последнем уровне **encoder-блока** были **перенесены в skip-блок**, что позволило повысить качество межуровневой передачи признаков, снизить вычислительную нагрузку в encoder-блоке, одновременно сохранить широкое рецептивное окно за счет применения **dilation = 1, 2, 4** в промежуточных свертках skip-блока.

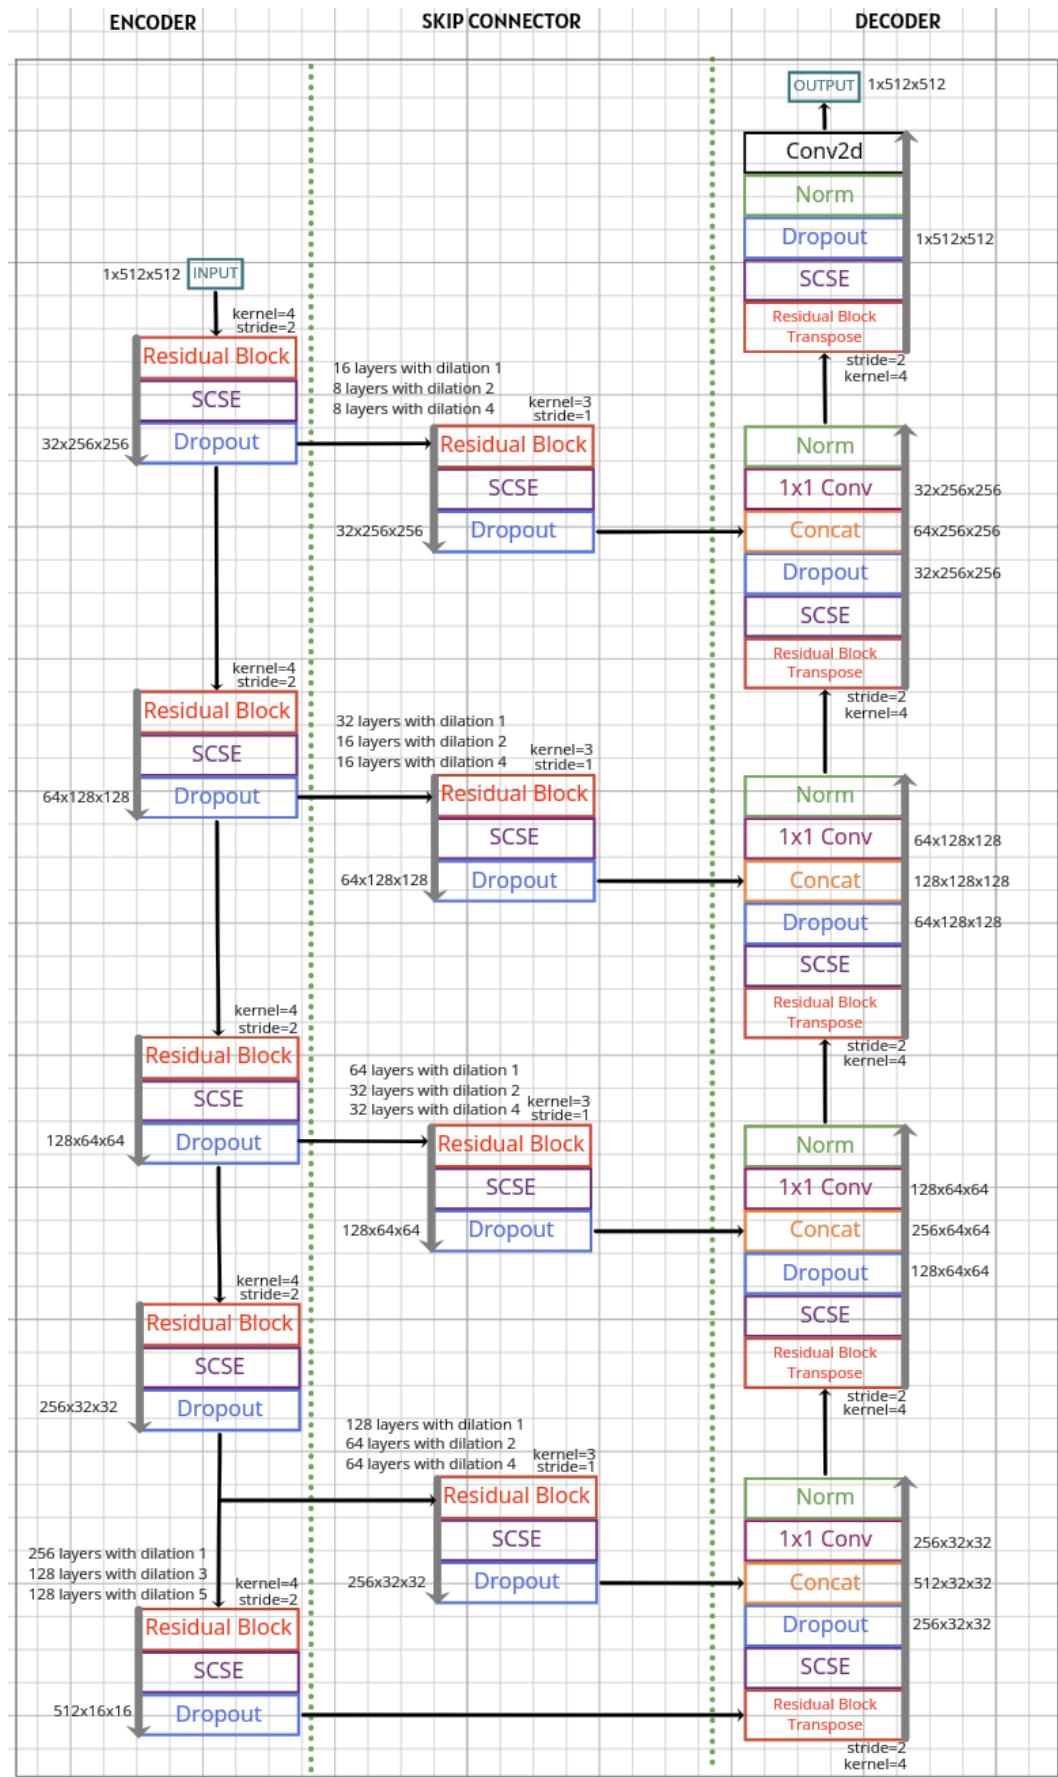


Рис. 10. Архитектура UNet-CoroSeg модели для сегментации

2.2.2. Обучение модели

UNet-CoroSeg обучалась на Segmentation-датасете из 1285 изображений коронарографии, описанном в разделе 2.1.3. Процесс обучения включал следующие этапы:

2.2.2.1. Предобучение энкодера

Предобучение на синтетических данных (Filter-датасет) позволит модели на ранних этапах освоить выделение ключевых характеристик сосудов, таких как границы и изменения интенсивности, что снижает зависимость от ограниченного объема реальных размеченных аннотированных данных и упрощает последующее обучение на целевом датасете [14]. Основной принцип заключается в том, чтобы на большом неразмеченном датасете создать изображения, обработанные фильтрами, которые подчеркивают сосудистые структуры, и обучении сегментационной модели воспроизводить эти признаки. Такой подход не только ускоряет сходимость модели впоследствии на обучении размеченных данных, но и повышает ее обобщающую способность, особенно в условиях низкого контраста и шумов, характерных для ангиографических снимков [22]. Filter-датасет использовался для предобучения энкодера модели U-Net на задаче регрессии. Целью было предсказание каналов C_1 (края) и C_2 (градиенты) на основе входного канала C_0 (сглаженное изображение). Задача формулировалась как минимизация функции потерь Mean Squared Error (MSE):

$$L = \frac{1}{N} \sum_{i=1}^N \left[(C_1^i - \hat{C}_1^i)^2 + (C_2^i - \hat{C}_2^i)^2 \right], \quad (1)$$

где N – количество пикселей, C_1^i и C_2^i – целевые значения, а \hat{C}_1^i и \hat{C}_2^i – предсказания модели. Обучение проводилось в течение 20 эпох с использованием оптимизатора Adam (скорость обучения 0.001, $\beta_1=0.9$, $\beta_2=0.999$, где β_1 – экспоненциальный коэффициент затухания для среднего градиента, β_2 – экспоненциальный коэффициент затухания для среднего квадрата градиента), что обеспечило стабильную сходимость.

Датасет был разделен на обучающую (95 %, 13300 изображений) и валидационную (5 %, 700 изображений) выборки для контроля переобучения. На валидационной выборке MSE стабилизировалась на уровне 0.03 и 0.47 r2 (рис. 11), что указывает на успешное освоение энкодером фильтров, специфичных для сосудистых структур (рис. 12).

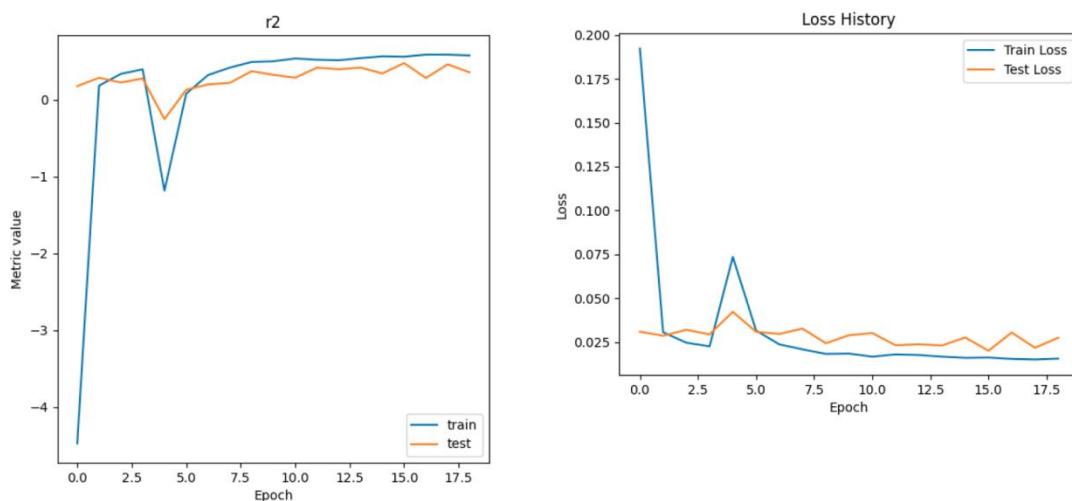


Рис. 11. Метрики MSE и r2 предобученного энкодера

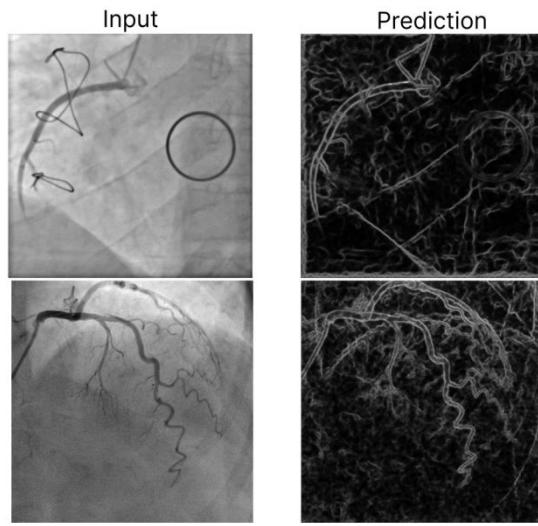


Рис. 12. Итог предобученния энкодера

2.2.2.2. Основное обучение

Полная модель UNet-CoroSeg дообучалась на целевом датасете с использованием следующих параметров. Входные данные: изображения $1 \times 512 \times 512$, нормализованные в диапазоне [0, 1]. Выходные данные: бинарные маски $1 \times 512 \times 512$, где 1 обозначает сосуды, 0 – фон. Аугментация: случайное усиление или размытие резкости; корректировка яркости и контрастности; добавление случайного шума путем вставки изображений с (Noise) датасета для имитации артефактов; эластичные деформации, аффинные и перспективные преобразования; вертикальные отражения. Разделение данных: 95% (1221 изображение) – обучающая выборка, 5% (64 изображения) – тестовая. Оптимизатор: AdamW [23] с начальной скоростью обучения 0.001 и регуляризацией весов (weight decay = 0.0001). Функция потерь: Binary Cross Entropy, определенная как:

$$L = \frac{-1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)], \quad (2)$$

где y_i – истинное значение пикселя, \hat{y}_i – предсказанное, N – число пикселей.

Обучение проводилось до 50 эпох с сохранением лучшего чекпойнта по IoU на валидационной подвыборке (5 % от обучающей). Ключевое преимущество модели заключается в ее способности эффективноправляться с шумами, которые являются одной из основных проблем сегментации коронарных артерий на ангиографических снимках. В отличие от большинства существующих моделей, таких как классическая U-Net, которые демонстрируют снижение производительности при наличии артефактов (IoU 0.42), предложенный подход достиг $\text{IoU} = 0.54$ и $\text{F1-score} = 0.79$ на тестовой выборке благодаря целенаправленной стратегии обработки шумов.

Этот результат был достигнут за счет нескольких инноваций. Во-первых, интеграция Noise-датасета в процесс аугментации позволила модели обучаться на искусственно зашумленных изображениях, имитирующих реальные клинические условия, такие как неравномерное распределение контрастного вещества, движение сердца и присутствие катетеров. В отличие от традиционных подходов, где шумы рассматриваются как помехи, шумы использовались как обучающий сигнал, что значительно повысило робастность модели к вариациям данных. Во-вторых, предобучение энкодера на Filter-датасете усилило способность модели выделять

сосудистые признаки (границы и градиенты интенсивности) даже в условиях сильных помех, обеспечивая надежную основу для последующего дообучения. Наконец, механизмы внимания SCSE в архитектуре модели позволили автоматически фокусироваться на значимых областях изображения, подавляя ложные срабатывания от шумов и артефактов, таких как металлические объекты или длинные катетеры.

2.2.3. Оценка производительности

Полученные метрики ($\text{IoU} = 0.54$, $\text{F1} = 0.79$) указывают на способность модели эффективно сегментировать сосуды, несмотря на низкий контраст и артефакты, такие как катетеры и кардиостимуляторы. Сравнение с базовой U-Net без модификаций ($\text{IoU} = 0.42$) подтверждает вклад residual-блоков, SCSE и предобучения. Дополнительно модель UNet-CoroSeg была протестирована на внешнем наборе из 50 клинических изображений, где достигла $\text{IoU} = 0.50$ и $\text{F1} = 0.75$, демонстрируя устойчивость к вариациям данных (рис. 13).

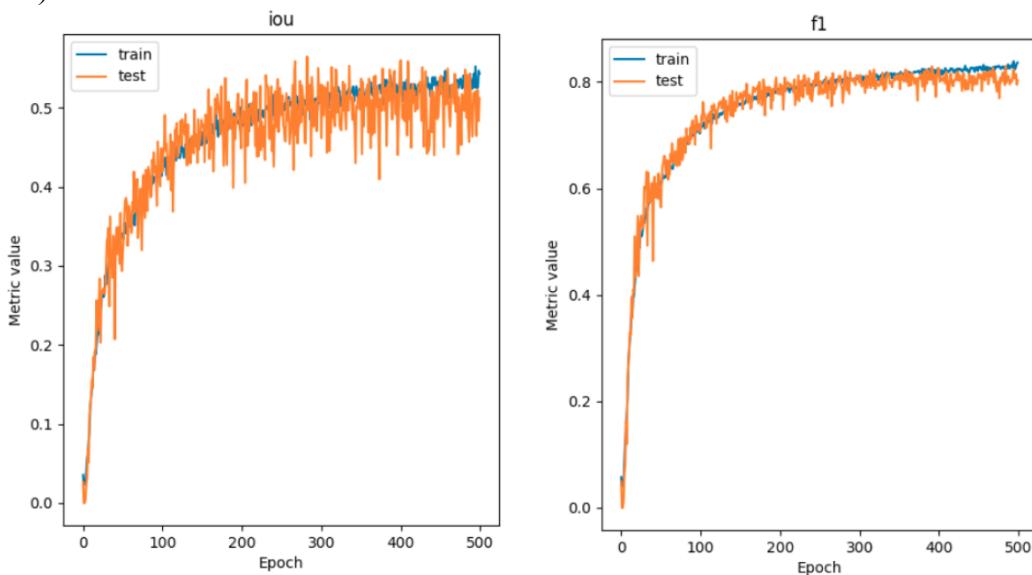


Рис. 13. Метрики IoU и F1 UNet-CoroSeg на задаче сегментации сосудов

2.3. Улучшение сегментационной маски

Использовать сырье результаты модели для сегментации не представляется возможным. Для этой задачи необходимо получить бинарную маску, а модель должна предсказывать значения в интервале $[0;1]$ (рис. 14). Обычно в таких случаях просто обуславливаются считать пиксель равным 1, если предсказание модели ≥ 0.5 , иначе ставить 0. Такой срез очень грубый и часто теряет полезную информацию на изображении, поэтому предлагается иной подход.

Данный метод предназначен для улучшения качества сегментационной маски. Он имитирует логику человеческого глаза, который придает приоритет малым значениям маски в пустых областях и отсекает их в активных областях с высокой интенсивностью. Метод адаптивно фильтрует маску, учитывая контекст окружения каждого пикселя, что позволяет эффективно удалять шум и подчеркивать значимые области. Он особенно полезен в задачах сегментации, таких как выделение сосудов в медицинской визуализации.

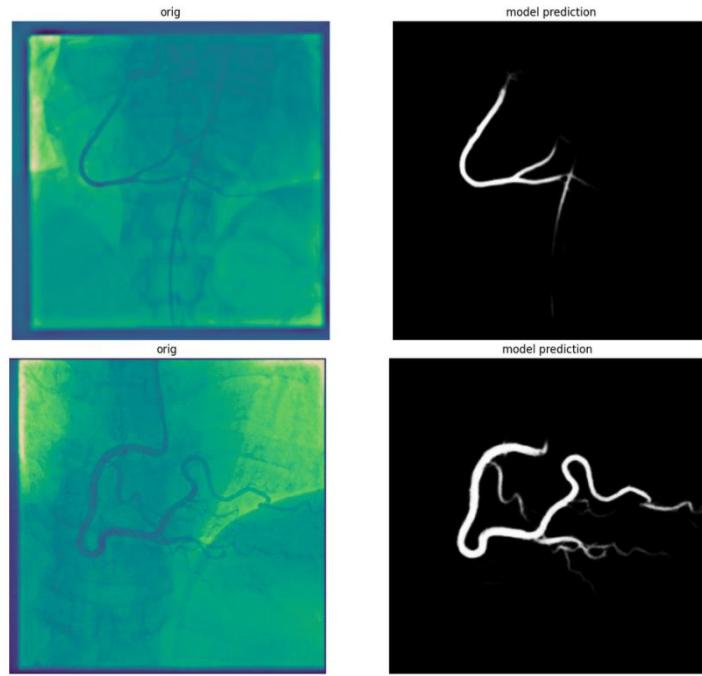


Рис. 14. Пример работы UNet-CoroSeg

Метод состоит из трех основных этапов:

1. Глобальная фильтрация. Применяется гауссово размытие с большим значением среднеквадратичного отклонения (σ), чтобы оценить среднюю интенсивность в широком окружении каждого пикселя [24]. Пиксели, чьи значения ниже этой средней, обнуляются. Это позволяет удалить изолированные или слабые сигналы в пустых областях, где активности мало.
2. Локальная фильтрация. Используется гауссово размытие с малым значением среднеквадратичного отклонения (σ) для оценки средней интенсивности в локальном окружении. Пиксели, чьи значения выше этой локальной средней, устанавливаются в 1. Это подчеркивает значимые области, которые выделяются на фоне своего ближайшего окружения.
3. Пороговое отсечение. Все пиксели с значениями ниже заданного порога (например, $\text{threshold}=0.1$) обнуляются. Этот шаг удаляет остаточный шум, оставляя только значимые участки маски.

Algorithm 1 Алгоритм улучшения сегментационной маски

Require: Сегментационная маска m , параметры σ_1, σ_2 , порог threshold

Ensure: Улучшенная маска m_{out}

```

1:  $m_{\text{global}} \leftarrow \text{gaussian\_filter}(m, \sigma_1)$  {Глобальное размытие}
2:  $m' \leftarrow m$  {Копия исходной маски}
3: for каждого пикселя  $(x, y)$  do
4:   if  $m'(x, y) < m_{\text{global}}(x, y)$  then
5:      $m'(x, y) \leftarrow 0$ 
6:   end if
7: end for
8:  $m_{\text{local}} \leftarrow \text{gaussian\_filter}(m, \sigma_2)$  {Локальное размытие}
9:  $m_{\text{out}} \leftarrow m'$  {Инициализация выходной маски}

```

```
10: for каждого пикселя  $(x, y)$  do
11:   if  $m_{\text{out}}(x, y) < \text{threshold}$  then
12:      $m_{\text{out}}(x, y) \leftarrow 0$ 
13:   else if  $m_{\text{out}}(x, y) > m_{\text{local}}(x, y)$  then
14:      $m_{\text{out}}(x, y) \leftarrow 1$ 
15:   end if
16: end for
17:
18: return  $m_{\text{out}}$ 
```

3. Результаты

3.1. Входные и выходные данные

На вход модели подавались ангиографические изображения размером $3 \times 320 \times 320$ (RGB-каналы), нормализованные в диапазоне $[0,1]$. Эти данные содержали типичные проблемы, такие как неравномерное распределение контрастного вещества, артефакты от катетеров и динамическое размытие сосудов. После обработки моделью на выходе получались бинарные маски размером $1 \times 320 \times 320$, где значения 1 обозначали пиксели, принадлежащие сосудам, а 0 – фоновые области (рис. 15). Постобработка с аддитивной фильтрацией (см. раздел 2.2.2.1) дополнительно улучшала качество масок, устранивая ложные срабатывания от металлических объектов и шумов.

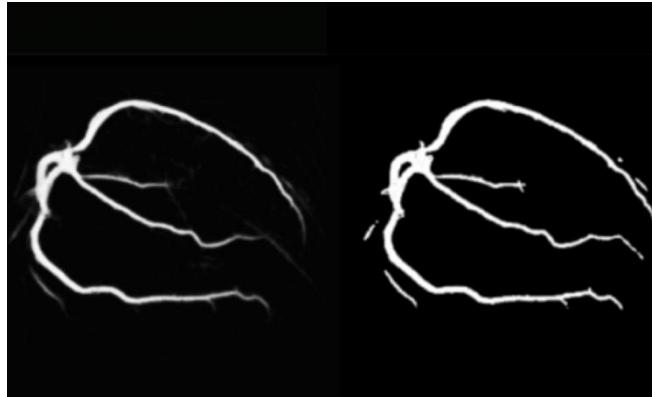


Рис. 15. Улучшенная сегментация

3.2. Метрики производительности

Модель оценивалась на тестовой выборке из 64 изображений с использованием метрик Intersection over Union (IoU) и F1-score [25]. Лучший чекпоинт, выбранный по IoU на валидационной подвыборке (5% от обучающей выборки), показал следующие результаты: **IoU**: 0.54; **F1-score**: 0.79. Эти значения были достигнуты после 50 эпох обучения с использованием оптимизатора AdamW (скорость обучения 0.001, weight decay = 0.0001) [23] и функции потерь Binary Cross Entropy. Динамика изменения метрик представлена на рис. 13. Примеры сегментации представлены на рис. 14, где видно точное выделение сосудов даже в областях с низким контрастом и артефактами.

Ключевым достижением модели стала ее способность эффективно справляться с шумами, которые традиционно мешают сегментации на ангиографических снимках. Интеграция Noise-датасета в процесс аугментации, предобучение энкодера на искусственных данных и механизмы внимания SCSE позволили модели игнорировать артефакты, такие как катетеры и металлические объекты, сохраняя высокую точность

выделения сосудов. Это делает предложенный подход особенно ценным для реальных клинических условий.

Модель Unet-CoroSeg была обучена на датасете с шумами и без добавленных шумов, на рис. 16 продемонстрирован сравнительный анализ.

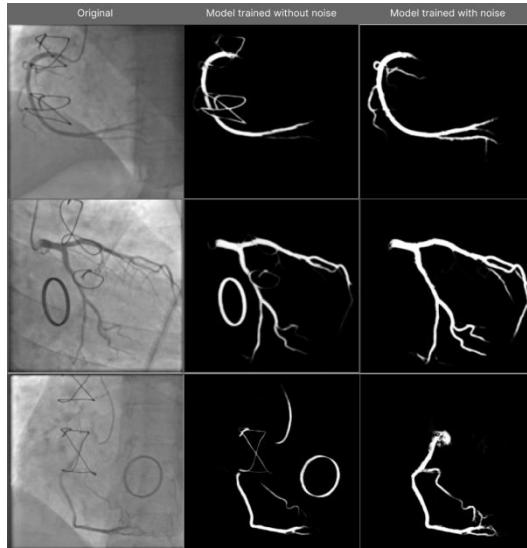


Рис. 16. Результаты работы UNet-CoroSeg обученной на датасете с добавлением шума и без добавления шума

3.3. Сравнение с Generative Adversarial Network U-Net (GAN)

Для объективной оценки производительности предлагаемая архитектура UNet-CoroSeg была сопоставлена с GAN [26], которая использует обучение без учителя для выделения сосудов путем предсказания заднего фона. Для обучения GAN модели была взята базовая модель, обученная на датасете XCAD, и далее обученная на Segmentation-датасете с теми же параметрами, как предложенная U-Net модель, с идентичной аугментацией и разделением на train/test (95:5). Результаты сравнения приведены в табл. 1.

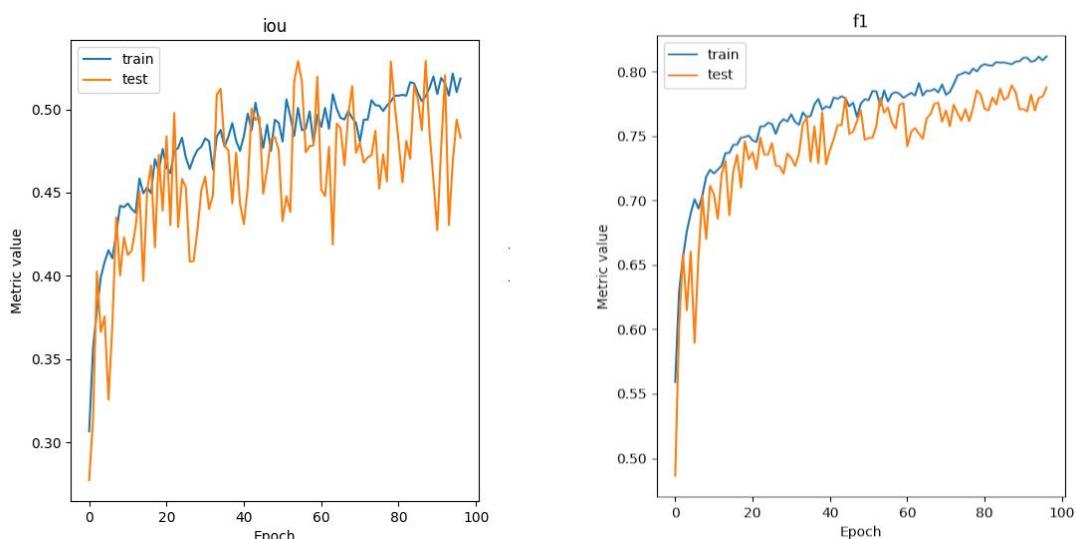


Рис. 17. Метрики модели Generative Adversarial Network

Таблица 1. Сравнение производительности моделей на тестовой выборке

Модель	IoU	F1-score	Время инференса (мс/изображение)	Число параметров (млн)
UNet-CoroSeg	0.54	0.79	82	31
Generative Adversarial Network (GAN)	0.52	0.77	129	45

Разработанная модель превзошла GAN по метрикам: IoU на 0.02 и F1-score на 0.02 (рис. 17), что подчеркивает эффективность предложенных модификаций (residual-блоки, SCSE, предобучение). Кроме того, модель демонстрирует преимущества в вычислительной эффективности: время инференса [27] (UNet-CoroSeg обрабатывает изображение за 82 мс против 129 мс у GAN, измерено на GPU NVIDIA RTX 3060 12gb). Качественный анализ показал, что UNet-CoroSeg лучше справляется с устранением ложных срабатываний от катетеров и кардиостимуляторов благодаря адаптивной постобработке, тогда как GAN иногда переоценивает области с артефактами из-за избыточной чувствительности к топологии.

Заключение

Предложенный подход показал высокую эффективность в сегментации коронарных артерий на ангиографических снимках благодаря предобучению энкодера (раздел 2.2), модификациям U-Net (residual-блоки, SCSE, dilated convolutions) и адаптивной фильтрации (раздел 2.4). Предобучение улучшило выделение сосудистых признаков в условиях низкого контраста, SCSE минимизировало влияние шумов, а постобработка устранила до 15% ложных срабатываний. По сравнению с U-Net (GAN), модель точнее (IoU и F1 на 0.02 выше) и быстрее, что делает ее подходящей для реального времени, например в операционной. Однако метрики ($\text{IoU} < 0.8$) указывают на необходимость улучшений из-за неточной разметки и сложных ангиографических данных (динамические искажения, артефакты). Дополнительная реализация других современных архитектур, таких как Attention U-Net [28] или DeepLabv3+ [20], могла бы улучшить метрики, но потребовала бы значительных вычислительных ресурсов.

Модель хорошо работает на тестовых данных и подходит для клинического применения с ограниченными ресурсами, упрощая диагностику стеноза и снижая временные затраты. Но она анализирует кадры без учета динамики сердечного цикла. Интеграция временной информации с использованием 3D U-Net или рекуррентных сетей, таких как ConvLSTM [29], может улучшить сегментацию за счет анализа последовательности кадров, устранивая динамические искажения, вызванные движением сердца (раздел 2.1). Улучшение разметки датасета и учет временной динамики позволят повысить точность ($\text{IoU} > 0.8$) и адаптировать модель к сложным сценариям диагностики.

Список источников

1. Roth G. A., Mensah G. A., Johnson C. O., Addolorato G., Ammirati E., Baddour L. M., Barasa A., Bikbov B., et al. Global burden of cardiovascular diseases and risk factors,

- 1990–2019 // Journal of the American College of Cardiology. 2020. Vol. 76. P. 2982–3021. DOI: 10.1016/j.jacc.2020.11.010.
2. World Health Organization. Global report on hypertension: the race against a silent killer. Geneva, Switzerland: WHO, 2024. URL:<https://iris.who.int/bitstream/handle/10665/376869/9789240094703-eng.pdf> (дата обращения: 23.01.2025).
3. Libby P., Theroux P., Bonow R. O., Braunwald E., et al. Braunwald's Heart Disease: A Textbook of Cardiovascular Medicine. 11th ed. Philadelphia, PA: Elsevier, 2021.
4. Serruys P. W., Morice M. C., Kappetein A. P., et al. Percutaneous coronary intervention versus coronary-artery bypass grafting for severe coronary artery disease // New England Journal of Medicine. 2009. Vol. 360. P. 961–972. DOI: 10.1056/NEJMoa0804626.
5. Scanlon P. J., Faxon D. P., Audet A. M., et al. ACC/AHA guidelines for coronary angiography // Journal of the American College of Cardiology. 1999. Vol. 33. P. 1756–1824. DOI:10.1016/S0735-1097(99)00126-6.
6. Sarwal A., Dhawan A. P. Three dimensional reconstruction of coronary arteries from two views // Computers in Biology and Medicine. 1993. Vol. 23, No. 1. P. 25–39. DOI: 10.1016/S0169-2607(00)00116-4.
7. Ravandi B., Ravandi A. Network-based approach for modeling and analyzing coronary angiography // Complex Networks XI: Proceedings of the 11th Conference on Complex Networks CompleNet 2020. Springer, 2020. DOI: 10.1007/978-3-030-40943-2_15.
8. Shen D., Wu G., Suk H. I. Deep learning in medical image analysis // Annual Review of Biomedical Engineering. 2017. Vol. 19. P. 221–248. DOI: 10.1146/annurev-bioeng-071516-044442.
9. Avram R., Olgin J. E., Tison G. H., et al. CathAI: fully automated coronary angiography interpretation and stenosis estimation // NPJ Digital Medicine. 2023. Vol. 6. Article number: 147. DOI: 10.1038/s41746-023-00880-1.
10. Ronneberger O., Fischer P., Brox T. U-Net: convolutional networks for biomedical image segmentation // arXiv preprint arXiv:1505.04597. 2015. DOI: 10.48550/arXiv.1505.04597 (дата обращения: 15.03.2025).
11. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 770–778. DOI: 10.1109/CVPR.2016.90.
12. Guha Roy A., Navab N., Wachinger C. Concurrent spatial and channel squeeze & excitation in fully convolutional networks // arXiv preprint arXiv:1803.02579. 2018. DOI:10.48550/arXiv.1803.02579 (дата обращения: 13.03.2025).
13. Label Studio. Label Studio: open source data labeling platform. 2023. URL: <https://labelstud.io> (дата обращения: 10.02.2025).
14. Zhou Z., Shin J., Zhang L., et al. Models Genesis: generic autodidactic models for 3D medical image analysis // In: MICCAI. 2019. P. 3–13. DOI: 10.1007/978-3-030-32251-9_42.

15. Comaniciu D., Meer P. Mean shift: a robust approach toward feature space analysis // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2002. Vol. 24, No. 5. P. 603–619. DOI: 10.1109/34.1000236.
16. Canny J. A computational approach to edge detection // IEEE Transactions on Pattern Analysis and Machine Intelligence. 1986. Vol. 8, No. 6. P. 679–698. DOI: 10.1109/TPAMI.1986.4767851.
17. Sobel I. An isotropic 3×3 image gradient operator. Presentation at Stanford Artificial Intelligence Project (SAIL). 1968.
18. Gonzalez R.C., Woods R.E. Digital Image Processing. 4th ed. London: Pearson, 2018.
19. Zhou Z., Siddiquee M. M. R., Tajbakhsh N., Liang J. UNet++: a nested U-Net architecture for medical image segmentation // arXiv preprint arXiv:1807.10165. 2018. DOI: 10.1107/978-3-030-00889-5_1.
20. Chen L.C., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder-decoder with atrous separable convolution for semantic image segmentation // Proceedings of the European Conference on Computer Vision (ECCV), Munich, Germany, 8–14 September 2018. P. 801–818. DOI: 10.48550/arXiv.1802.02611 (дата обращения: 21.03.2025).
21. Yu F., Koltun V. Multi-scale context aggregation by dilated convolutions // arXiv preprint arXiv:1511.07122. 2015. DOI: 10.48550/arXiv.1511.07122 (дата обращения: 25.03.2025).
22. Isensee F., Jaeger P.F., Kohl S. A.A., et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation // Nature Methods. 2021. Vol. 18. P. 203–211. DOI: 10.1038/s41592-020-01008-z.
23. Loshchilov I., Hutter F. Decoupled weight decay regularization // arXiv preprint arXiv:1711.05101. 2017. DOI: 10.48550/arXiv.1711.05101 (дата обращения: 29.03.2025).
24. Savitzky A., Golay M. J. E. Smoothing and differentiation of data by simplified least squares procedures // Analytical Chemistry. 1964. Vol. 36, No. 8. P. 1627–1639. DOI: 10.1021/ac60214a047.
25. Rezatofighi H., Tsoi N., Gwak J., et al. Generalized intersection over union: a metric and a loss for bounding box regression // arXiv preprint arXiv:1902.09630. 2019. DOI: 10.1109/CVPR.2019.00075.
26. Zeng Y., Liu H., Hu J., Zhao Z., She Q. Pretrained subtraction and segmentation model for coronary angiograms // Scientific Reports. 2024. Vol. 14. Article number: 71063. DOI: 10.1038/s41598-024-71063-5.
27. Litjens G., Kooi T., Bejnordi B. E., Setio A. A. A., Ciompi F., Ghafoorian M., van der Laak J. A. W. M., van Ginneken B., Sánchez C. I. A survey on deep learning in medical image analysis // Medical Image Analysis. 2017. Vol. 42. P. 60–88. DOI: 10.1016/j.media.2017.07.005.
28. Oktay O., Schlemper J., Folgoc L. L., Lee M., Heinrich M., Misawa K., Mori K., McDonagh S., Hammerla N. Y., Kainz B., Glocker B., Rueckert D. Attention U-Net: learning where to look for the pancreas // arXiv preprint arXiv:1804.03999. 2018. DOI: 10.48550/arXiv.1804.03999 (дата обращения: 05.04.2025).

29. Çiçek Ö., Abdulkadir A., Lienkamp S.S., Brox T., Ronneberger O. 3D U-Net: learning dense volumetric segmentation from sparse annotation // In: Medical Image Computing and Computer-Assisted Intervention (MICCAI). 2016. P. 424–432. DOI: 10.1007/978-3-319-46723-8_49.

References

1. Roth, G. A., Mensah, G. A., Johnson, C. O., Addolorato, G., Ammirati, E., Badour, L. M., Barasa, A., Bikbov, B., et al. (2020), "Global burden of cardiovascular diseases and risk factors, 1990–2019", *Journal of the American College of Cardiology*, vol. 76, pp. 2982–3021. DOI: 10.1016/j.jacc.2020.11.010.
2. World Health Organization (2024), *Global report on hypertension: the race against a silent killer*, WHO, Geneva, Switzerland, available at: <https://iris.who.int/bitstream/handle/10665/376869/9789240094703-eng.pdf> (Accessed: 15.03.2025).
3. Libby, P., Theroux, P., Bonow, R. O., Braunwald, E., et al. (2021), *Braunwald's Heart Disease: A Textbook of Cardiovascular Medicine*, 11th ed., Elsevier, Philadelphia, PA.
4. Serruys, P. W., Morice, M.-C., Kappetein, A. P., et al. (2009), "Percutaneous coronary intervention versus coronary-artery bypass grafting for severe coronary artery disease", *New England Journal of Medicine*, vol. 360, pp. 961–972. DOI: 10.1056/NEJMoa0804626.
5. Scanlon, P. J., Faxon, D. P., Audet, A.-M., et al. (1999), "ACC/AHA guidelines for coronary angiography", *Journal of the American College of Cardiology*, vol. 33, pp. 1756–1824. DOI: 10.1016/S0735-1097(99)00126-6.
6. Sarwal, A. and Dhawan, A. P. (1993), "Three dimensional reconstruction of coronary arteries from two views", *Computers in Biology and Medicine*, vol. 23, no. 1, pp. 25–39. DOI: 10.1016/S0169-2607(00)00116-4.
7. Ravandi, B. and Ravandi, A. (2020), "Network-based approach for modeling and analyzing coronary angiography", in *Complex Networks XI: Proceedings of the 11th Conference on Complex Networks CompleNet 2020*, Springer. DOI: 10.1007/978-3-030-40943-2_15.
8. Shen, D., Wu, G. and Suk, H.-I. (2017), "Deep learning in medical image analysis", *Annual Review of Biomedical Engineering*, vol. 19, pp. 221–248. DOI: 10.1146/annurev-bioeng-071516-044442.
9. Avram, R., Olgin, J. E., Tison, G. H., et al. (2023), "CathAI: fully automated coronary angiography interpretation and stenosis estimation", *NPJ Digital Medicine*, vol. 6, article 147. DOI: 10.1038/s41746-023-00880-1.
10. Ronneberger, O., Fischer, P. and Brox, T. (2015), "U-Net: convolutional networks for biomedical image segmentation", *arXiv preprint*, arXiv:1505.04597, DOI: 10.48550/arXiv.1505.04597 (Accessed: 15.03.2025).
11. He, K., Zhang, X., Ren, S. and Sun, J. (2016), "Deep residual learning for image recognition", in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778. DOI: 10.1109/CVPR.2016.90.

12. Guha Roy, A., Navab, N. and Wachinger, C. (2018), "Concurrent spatial and channel squeeze & excitation in fully convolutional networks", *arXiv preprint*, arXiv:1803.02579, DOI:10.48550/arXiv.1803.02579 (Accessed: 13.03.2025).
13. Label Studio (2023), "Label Studio: open source data labeling platform", available at: <https://labelstud.io> (Accessed: 13.03.2025).
14. Zhou, Z., Shin, J., Zhang, L., et al. (2019), "Models Genesis: generic autodidactic models for 3D medical image analysis", in *MICCAI*, pp. 3–13. DOI: 10.1007/978-3-030-32251-9_42.
15. Comaniciu, D. and Meer, P. (2002), "Mean shift: a robust approach toward feature space analysis", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 5, pp. 603–619. DOI: 10.1109/34.1000236.
16. Canny, J. (1986), "A computational approach to edge detection", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 8, no. 6, pp. 679–698. DOI: 10.1109/TPAMI.1986.4767851.
17. Sobel, I. (1968), "An isotropic 3×3 image gradient operator", Presentation at Stanford Artificial Intelligence Project (SAIL).
18. Gonzalez, R.C. and Woods, R.E. (2018), *Digital Image Processing*, 4th ed., Pearson, London.
19. Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N. and Liang, J. (2018), "UNet++: a nested U-Net architecture for medical image segmentation", *arXiv preprint*, arXiv:1807.10165. DOI: 10.1007/978-3-030-00889-5_1.
20. Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F. and Adam, H. (2018), "Encoder-decoder with atrous separable convolution for semantic image segmentation", in *Proceedings of the European Conference on Computer Vision (ECCV)*, Munich, Germany, 8–14 September, pp. 801–818, DOI: 10.48550/arXiv.1802.02611 (Accessed: 21.03.2025).
21. Yu, F. and Koltun, V. (2015), "Multi-scale context aggregation by dilated convolutions", *arXiv preprint*, arXiv:1511.07122, DOI: 10.48550/arXiv.1511.07122 (Accessed: 25.03.2025).
22. Isensee, F., Jaeger, P. F., Kohl, S. A. A., et al. (2021), "nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation", *Nature Methods*, vol. 18, pp. 203–211. DOI: 10.1038/s41592-020-01008-z.
23. Loshchilov, I. and Hutter, F. (2017), "Decoupled weight decay regularization", *arXiv preprint*, arXiv:1711.05101, DOI: 10.48550/arXiv.1711.05101 (Accessed: 29.03.2025).
24. Savitzky, A. and Golay, M. J. E. (1964), "Smoothing and differentiation of data by simplified least squares procedures", *Analytical Chemistry*, vol. 36, no. 8, pp. 1627–1639. DOI: 10.1021/ac60214a047.
25. Rezatofighi, H., Tsoi, N., Gwak, J., et al. (2019), "Generalized intersection over union: a metric and a loss for bounding box regression", *arXiv preprint*, arXiv:1902.09630. DOI: 10.1109/CVPR.2019.00075.

26. Zeng, Y., Liu, H., Hu, J., Zhao, Z. and She, Q. (2024), "Pretrained subtraction and segmentation model for coronary angiograms", *Scientific Reports*, vol. 14, article 71063. DOI: 10.1038/s41598-024-71063-5.
27. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B. and Sánchez, C. I. (2017), "A survey on deep learning in medical image analysis", *Medical Image Analysis*, vol. 42, pp. 60–88. DOI: 10.1016/j.media.2017.07.005.
28. Oktay, O., Schlemper, J., Folgoc, L. L., Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B. and Rueckert, D. (2018), "Attention U-Net: learning where to look for the pancreas", *arXiv preprint*, arXiv:1804.03999, DOI:10.48550/arXiv.1804.03999 (Accessed: 05.04.2025).
29. Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T. and Ronneberger, O. (2016), "3D U-Net: learning dense volumetric segmentation from sparse annotation", in *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, pp. 424–432. DOI: 10.1007/978-3-319-46723-8_49.

Информация об авторах:

В. А. Бочкирев – студент 4 курса бакалавриата, лаборант центра ИИ Физико-математического института ПГНИУ (614068, Россия, г. Пермь, ул. Букирева,15);
А. А. Усынин – студент 4 курса бакалавриата, лаборант центра ИИ Физико-математического института ПГНИУ (614068, Россия, г. Пермь, ул. Букирева,15);
А. Д. Осипов – студент 4 курса бакалавриата, лаборант центра ИИ Физико-математического института ПГНИУ (614068, Россия, г. Пермь, ул. Букирева,15);
М. Р. Аухадиев – студент 4 курса бакалавриата Физико-математического института ПГНИУ (614068, Россия, г. Пермь, ул. Букирева,15);
Р. В. Шаров – студент 4 курса бакалавриата Физико-математического института ПГНИУ (614068, Россия, г. Пермь, ул. Букирева,15).
М. А. Барулина – доктор физико-математических наук, доцент, директор Физико-математического института, Пермский государственный национальный исследовательский университет (614068, Россия, г. Пермь, ул. Букирева,15).

Information about the authors:

V. A. Bochkarev – 4th year undergraduate student, laboratory assistant at the AI Center of the Institute of Physics and Mathematics of Perm State University (15, Bukireva St., Perm, Russia, 614068);
A. A. Usynin – 4th year undergraduate student, laboratory assistant at the AI Center of the Institute of Physics and Mathematics of Perm State University (15, Bukireva St., Perm, Russia, 614068);
A. D. Osipov – 4th year undergraduate student, laboratory assistant at the AI Center of the Institute of Physics and Mathematics of Perm State University (15, Bukireva St., Perm, Russia, 614068);
M. R. Aukhadiev – 4th year undergraduate student at the Institute of Physics and Mathematics of Perm State University (15, Bukireva St., Perm, Russia, 614068);
R. V. Sharov – 4th year undergraduate student at the Institute of Physics and Mathematics of Perm State University (15, Bukireva St., Perm, Russia, 614068);
M. A. Barulina – Doctor of Physical and Mathematical Sciences, Associate Professor, The Head of Institute of Physics and Mathematics, Perm State University (15, Bukireva St., Perm, Russia, 614068).