

Лаптев В. В.<sup>1</sup>, Данилов В. В.<sup>2</sup>, Овчаренко Е. А.<sup>1</sup>, Клышников К. Ю.<sup>1</sup>, Арнт А. А.<sup>1</sup>,  
Колесников А. Ю.<sup>1</sup>, Бессонов И. С.<sup>3</sup>, Литвинюк Н. В.<sup>4</sup>, Кочергин Н. А.<sup>1</sup>

<sup>1</sup> Научно-исследовательский институт комплексных проблем сердечно-сосудистых заболеваний, Кемерово, Россия

<sup>2</sup> Университет Помпеу Фабра, Барселона, Испания

<sup>3</sup> Тюменский кардиологический научный центр, Тюмень, Россия

<sup>4</sup> Красноярская краевая клиническая больница, Красноярск, Россия

## СЕГМЕНТАЦИЯ СТРУКТУРНЫХ КОМПОНЕНТОВ АТЕРОСКЛЕРОТИЧЕСКИХ БЛЯШЕК В ИЗОБРАЖЕНИЯХ ОПТИЧЕСКОЙ КОГЕРЕНТНОЙ ТОМОГРАФИИ С ПРИМЕНЕНИЕМ ГЛУБОКОГО МАШИННОГО ОБУЧЕНИЯ

<b>Цель</b>	Разработка оптимального метода автоматизированной сегментации структурных компонентов атеросклеротических бляшек в изображениях оптической когерентной томографии (ОКТ) с использованием ансамбля нейросетевых моделей глубокого обучения, основанного на сравнении девяти архитектур искусственных нейронных сетей.
<b>Материал и методы</b>	В исследовании использовался многопрофильный набор данных ОКТ, полученных в результате обследования 103 пациентов. Каждый сеанс ОКТ был аннотирован в виде набора двумерных бинарных масок, соответствующих пиксельным границам четырех ключевых морфологических особенностей бляшек: сосудистый просвет, фиброзная покрышка, липидное ядро и микрососуды. Для сегментации анатомических структур были применены девять моделей глубокого машинного обучения, включая U-Net, DeepLabV3 и др. Гиперпараметры моделей настраивали с использованием байесовской оптимизации, а оценку производительности выполняли при помощи метрики Dice Similarity Coefficient (DSC).
<b>Результаты</b>	Модели продемонстрировали высокую точность сегментации для сосудистого просвета (DSC: 0,987), умеренную точность для фиброзной покрышки (DSC: 0,736) и липидного ядра (DSC: 0,751). Сегментация микрососудов оказалась более сложной задачей, конечная точность по метрике DSC составила 61%. Взвешенный ансамбль моделей, учитывающий неравномерное представление различных морфологических структур и уверенность моделей, достиг среднего уровня DSC 88,2%, что значительно улучшило общую точность по сравнению с индивидуальными моделями. Полученное значение точности превышает показатели всех индивидуальных моделей, включая максимальные значения DSC 0,784 (для микрососудов) и 0,751 (для липидного ядра), что указывает на устойчивое улучшение точности сегментации при интеграции моделей.
<b>Заключение</b>	Исследование подтверждает эффективность предложенной стратегии сегментации атеросклеротических бляшек в ОКТ-изображениях, основанной на использовании специализированных моделей для различных морфологических особенностей и взвешенного ансамбля, адаптированного к неравномерному представлению различных морфологических структур и морфологической сложности. Данный подход позволил достичь высокой точности сегментации несмотря на выраженное неравенство представления классов. Представленные результаты могут способствовать развитию методов поддержки принятия решений в кардиологии, направленных на повышение точности диагностики и улучшение лечения сердечно-сосудистых заболеваний.
<b>Ключевые слова</b>	Атеросклероз; оптическая когерентная томография; машинное обучение; глубокое обучение; сегментация бляшек; диагностика сердечно-сосудистой системы; автоматизированная визуализация; уязвимые бляшки
<b>Для цитирования</b>	Laptev V. V., Danilov V. V., Ovcharenko E. A., Klyshnikov K. Yu., Arnt A. A., Kolesnikov A. Yu. et al. Segmentation of Structural Components of Atherosclerotic Plaques on OCT Images Using Deep Machine Learning. Kardiologiya. 2025;65(9):45–55. [Russian: Лаптев В. В., Данилов В. В., Овчаренко Е. А., Клышников К. Ю., Арнт А. А., Колесников А. Ю. и др. Сегментация структурных компонентов атеросклеротических бляшек в изображениях оптической когерентной томографии с применением глубокого машинного обучения. Кардиология. 2025;65(9):45–55].
<b>Автор для переписки</b>	Лаптев Владислав Витальевич. E-mail: lptwlad1@gmail.com

## Введение

Атеросклероз служит одной из ведущих причин сердечно-сосудистых заболеваний, таких как инфаркт миокарда, инсульт и заболевания периферических артерий. Это заболевание характеризуется образованием липидных бляшек в стенках артерий, что приводит к сужению просвета сосудов, нарушению кровотока и повышению риска развития тромботических осложнений [1, 2]. В 2021 г. ишемическая болезнь сердца, вызванная атеросклерозом, стала причиной более 10 млн смертей по всему миру, оставаясь основной причиной смертности как в экономически развитых, так и развивающихся странах [3].

Клиническая опасность атеросклероза обусловлена не только прогрессирующим сужением сосудов, но и нестабильностью атеросклеротических бляшек (АСБ). Некоторые бляшки остаются стабильными и бессимптомными, тогда как другие склонны к разрыву, что может привести к острым коронарным синдромам и инсультам [4, 5]. Ключевыми признаками уязвимых АСБ являются тонкая фиброзная покрышка и большое липидное ядро [6]. Выявление таких бляшек имеет критическое значение для предотвращения сердечно-сосудистых осложнений (ССО) [7].

Для диагностики и оценки атеросклероза используются различные интраваскулярные методы визуализации, такие как внутрисосудистое ультразвуковое исследование (ВСУЗИ, IVUS), оптическая когерентная томография (ОКТ) и спектроскопия в ближнем инфракрасном диапазоне (NIRS) [4, 8–10]. Эти методы обладают преимуществами перед традиционной коронарографией и компьютерной томографической ангиографией, которые, хотя и полезны для оценки степени стеноза, имеют ограничения в определении состава и уязвимости АСБ [11]. ОКТ,

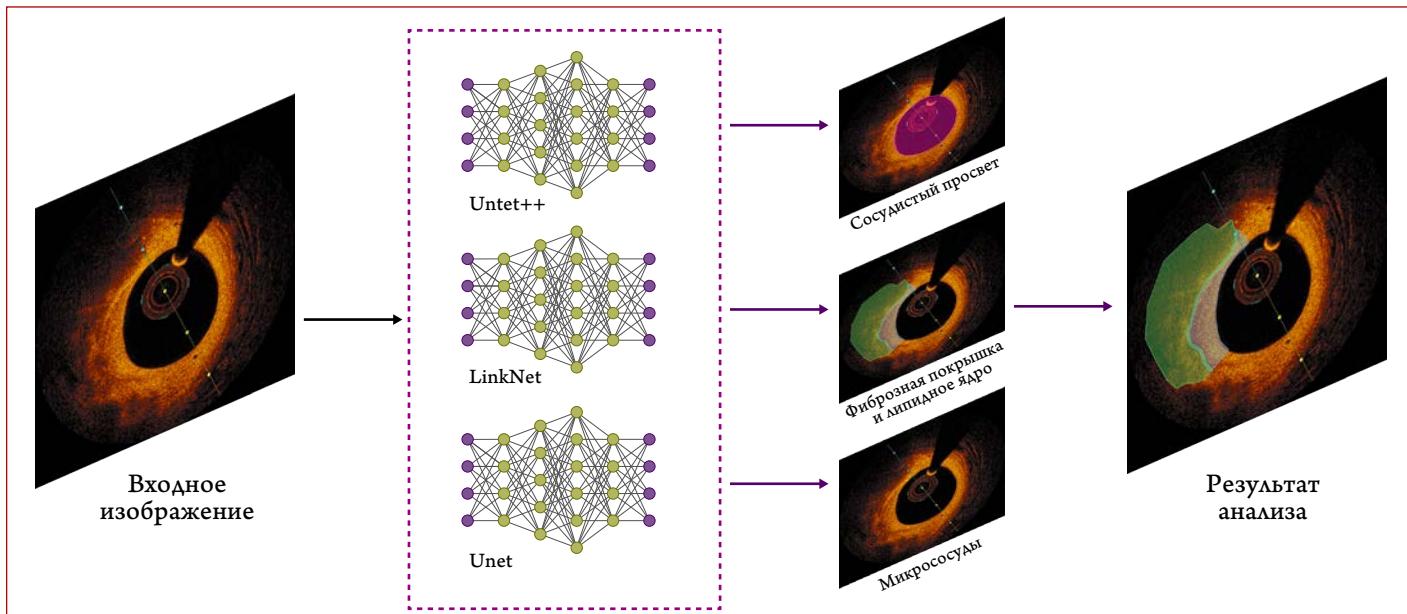
в частности, выделяется своим высоким разрешением, что позволяет визуализировать микроструктуры, такие как фиброзная покрышка и тромбы, что делает этот метод незаменимым для оценки уязвимости бляшек и проведения чрескожного коронарного вмешательства (ЧКВ) [12].

Однако стоит отметить, что ручной анализ ОКТ-изображений является трудоемким и напрямую зависит от опыта выполняющего его специалиста, что ограничивает его применение в клинической практике [13, 14]. В последние годы методы машинного обучения (МО), особенно глубокое обучение, стали мощным инструментом для автоматизации анализа внутрисосудистых изображений [15]. Например, предыдущие исследования продемонстрировали возможность автоматической сегментации и классификации различных типов АСБ, таких как кальцифицированные и липидные области [14]. Тем не менее при применении существующих подходов исследователи часто сталкиваются с проблемами, такими как неравномерное представление различных исследуемых структур, ограниченная вычислительная эффективность и недостаточная обобщающая способность модели на разнородных данных [16].

## Цель

Предложить новый гибридный подход к сегментации АСБ при анализе ОКТ-изображений, который сочетает специализированные модели для различных морфологических особенностей и использует взвешенный ансамбль для улучшения точности и эффективности [17]. Данный подход направлен на преодоление ограничений существующих методов и повышение клинической применимости автоматизированного анализа ОКТ-изображений [9, 16–19].

**Центральная иллюстрация.** Сегментация структурных компонентов атеросклеротических бляшек в изображениях оптической когерентной томографии с применением глубокого машинного обучения



## Материал и методы

В настоящем исследовании для решения задачи сегментации и количественной оценки АСБ был сформирован многопрофильный набор ОКТ-изображений, полученных от пациентов с атеросклерозом. Каждое ОКТ-изображение представляет собой трехмерный объем размерами  $N \times N \times M$ , где  $N$  – высота и ширина изображения в пикселях, а  $M$  – количество срезов, отражающих глубину изображения. Набор данных охватывает различные медицинские учреждения, типы сканеров и демографические характеристики пациентов, что делает его подходящим для обучения моделей, способных точно и надежно сегментировать АСБ в различных клинических условиях.

### Основные характеристики набора данных

#### 1. Медицинские учреждения.

Данные собраны из двух ведущих кардиологических исследовательских центров: Научно-исследовательский институт комплексных проблем сердечно-сосудистых заболеваний (Кемерово, Россия): 73 ОКТ; Тюменский кардиологический научный центр (Тюмень, Россия): 30 ОКТ.

#### 2. Типы сканеров.

Набор данных включает изображения, полученные с использованием сканеров двух различных производителей: St. Jude Medical и LightLab Imaging. Это обеспечивает разнородность данных и положительно влияет на обобщающую способность моделей для различных технологий визуализации.

#### 3. Период сбора данных.

ОКТ-исследования собирались в течение года, с 30 июня 2022 г. по 11 июля 2023 г., что позволяет учитывать временные изменения в практике визуализации и характеристиках пациентов.

#### 4. Гендерное распределение.

Набор данных включает ОКТ-изображения от 77 мужчин и 26 женщин, что обеспечивает разнообразие для анализа половых различий в морфологии АСБ.

#### 5. Размеры изображений.

Высота и ширина ОКТ-изображений варьируют от  $704 \times 704$  пикселей до  $1024 \times 1024$  пикселей, что отражает разнообразие анатомических особенностей и условий визуализации.

#### 6. Глубина изображений.

Количество срезов на одно исследование варьирует от 215 до 270, что соответствует различной глубине визуализации, используемой в диагностических процедурах.

Исследование проводилось в соответствии с принципами Хельсинкской декларации и одобрено локальным этическим комитетом Научно-исследовательского институ

тута комплексных проблем сердечно-сосудистых заболеваний, протокол № 2022/06 от 30 июня 2022 г. (Кемерово, Россия). Все участники предоставили письменное информированное согласие перед включением в исследование.

В исследование включены 103 пациента в возрасте 18 лет и старше с диагностированной стабильной ишемической болезнью сердца, проходящие катетеризацию сердца. Из них 77 (74,7%) мужчин и 26 (25,3%) женщин. У большинства пациентов наблюдались сопутствующие заболевания, включая сахарный диабет (21,4%) и инфаркт миокарда в анамнезе (21,4%). Все поражения с ангиографически подтвержденным стенозом диаметра 50–90%, определенным результатами визуальной оценки, были функционально оценены с использованием фракционного резерва кровотока (FFR). Поражения с промежуточным, не ограничивающим кровоток значением FFR ( $>0,80$ ) дополнительно оценивались с помощью ОКТ. При поражениях с ограничением кровотока ( $FFR \leq 0,80$ ) выполнялось ЧКВ с имплантацией стентов с лекарственным покрытием.

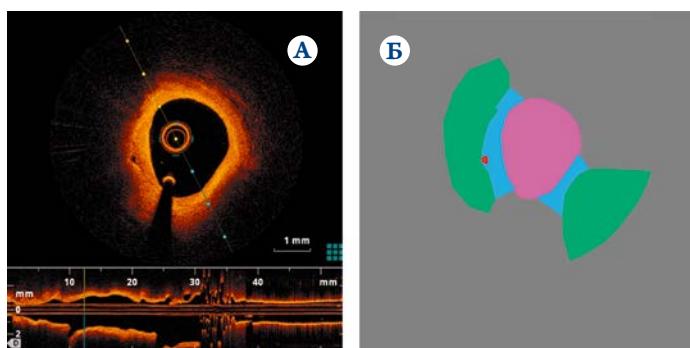
Клинические проявления были различными, у 91,3% пациентов имелась стенокардия I–III функционального класса, тогда как у 8,7% наблюдалась бессимптомная ишемия. Эти разнообразные характеристики пациентов, представленные в таблице 1, повышают клиническую релевантность набора данных и обеспечивают основу для изучения вариаций в морфологии АСБ.

После сбора данных два кардиолога тщательно аннотировали 103 ОКТ-исследования, которые включали 25698 RGB-срезов. В процессе аннотирования выделены четыре ключевые морфологические особенности АСБ, связанные с различными паттернами развития заболевания: сосудистый просвет, фиброзная покрышка, липидное ядро и микрососуды. Каждая из этих особенностей была аннотирована с использованием бинарных масок, как показано на рисунке 1. Аннотирование проводили с использованием веб-платформы для компьютерного зрения Supervisely [20].

**Таблица 1. Исходные характеристики пациентов, включенных в исследование**

Характеристика	Значение
Пол	
Муж, <i>n</i> (%)	77 (74,7)
Жен, <i>n</i> (%)	26 (25,3)
Средний возраст, годы (min–max)	69,0 (43,0–83,0)
Артериальная гипертензия, <i>n</i> (%)	92 (89,3)
Сахарный диабет, <i>n</i> (%)	22 (21,4)
Инфаркт миокарда, <i>n</i> (%)	22 (21,4)
Мультифокальный атеросклероз, <i>n</i> (%)	29 (28,2)
Стенокардия, <i>n</i> (%)	
• безболевая ишемия	9 (8,7)
• функциональный класс I	24 (23,3)
• функциональный класс II	55 (53,4)
• функциональный класс III	15 (14,6)

Рисунок 1. Методология аннотирования ОКТ-изображений



А – входное исходное изображение; Б – сегментационная маска изображения, где каждая особенность выделена цветом: сосудистый просвет – розовый, фиброзная покрышка – синий, липидное ядро – зеленый, микрососуды – красный.

После первоначального аннотирования все размеченные срезы были проверены и повторно верифицированы старшим кардиологом и техническим специалистом, отвечающим за подготовку набора данных. Этот процесс включал корректировку и исправление аннотаций для обеспечения их точности и согласованности. Двойная проверка позволила минимизировать ошибки и повысить качество данных.

#### Описание аннотированных особенностей

- просвет сосудов (Lumen, LM) – особенность связана с измерением размеров просвета сосудов, что важно для оценки степени стеноза и кровотока. Точное измерение просвета помогает определить тяжесть сосудистых нарушений и принять клинические решения;
- фиброзная покрышка (Fibrous Cap, FC) характеризуется толщиной и структурой фиброзного слоя, покрывающего бляшку. Эта особенность играет ключевую роль в оценке уязвимости АСБ, так как тонкая фиброзная покрышка увеличивает риск разрыва и развития ССО;
- липидное ядро (Lipid Core, LC) представляет собой область бляшки с высоким содержанием липидов. Количественная оценка липидного ядра служит важным показателем активности атеросклероза и помогает выявить высокорисковые АСБ, которые могут привести к клинически значимым осложнениям, таким как инфаркт миокарда;
- микрососуды (vasa vasorum, VV) – мелкие кровеносные сосуды, питающие стенки артерий. Их наличие и распределение связаны с воспалительными процессами и могут служить маркерами воспаления бляшки и общего состояния сосудов.

Каждая из представленных особенностей играет важную роль в понимании структуры и прогрессирования атеросклеротического заболевания. Просвет отражает степень сужения сосуда и влияет на кровоток, тогда как фиброзная покрышка, липидное ядро и микрососуды являются ключевыми маркерами уязвимости бляшки.

Сегментация и количественная оценка этих особенностей в ОКТ-изображениях позволяют проводить детальный анализ морфологии АСБ, что способствует улучшению диагностики и прогнозирования развития атеросклероза.

#### Выбор моделей

Для сегментации четырех морфологических особенностей бляшек в ОКТ-изображениях (просвет сосудов, фиброзная покрышка, липидное ядро и микрососуды) были выбраны и оценены девять различных архитектур искусственных нейронных сетей (ИНС), которые хорошо зарекомендовали себя в задачах анализа сложных биомедицинских изображений [21]. Эти модели включают следующие: U-Net [22], U-Net++ [23], DeepLabV3 [24], DeepLabV3+ [25], Feature Pyramid Network (FPN) [26], LinkNet [27], PSPNet [28], Pyramid Attention Network (PAN) [29], MA-Net (Multi-Attention Network) [30].

Выбор этих девяти моделей был обусловлен их способностью эффективно работать с локальными и глобальными признаками, сохранять высокое разрешение изображений и обрабатывать сложные анатомические структуры. Каждая из моделей имеет уникальные преимущества, что позволяет провести всестороннее сравнение и выбрать наиболее подходящую архитектуру для задач сегментации АСБ в ОКТ-исследованиях. Таким образом, выбор моделей был основан на их эффективности в задачах биомедицинской сегментации, а также на их способности обрабатывать сложные и разнородные структуры, характерные для АСБ. Это обеспечивает надежную основу для дальнейшей оптимизации и интеграции моделей в клиническую практику.

Разработка моделей сегментации была обусловлена неравномерным распределением анатомических признаков в наборе данных и отличительными характеристиками каждого класса. Как показано в таблице 2, наиболее распространенными являются объекты просвета, включающие 21 808 экземпляров, за ними следуют фиброзная покрышка (7 226 экземпляров) и липидное ядро (7 192 экземпляра). Класс микрососудов имеет значительно меньшее представление – всего 450 экземпляров.

Для решения данной задачи мы использовали гибридную стратегию сегментации, адаптированную к специальному распределению и морфологической сложности каждого целевого класса:

- сегментация LM: обучена одноклассовая модель, основанная высоким представлением в данных;
- сегментация FC и LC: эти два класса, умеренно представленные, имеют общие морфологические черты, такие как сложные и перекрывающиеся границы. Двухклассовая модель была настроена и обучена для повышения точности сегментации каждого представленного признака;

Таблица 2. Распределение морфологических признаков и изображений по подмножествам

Выборка	Множество	LM	FC	LC	VV	Всего объектов	Всего изображений
1	Тренировочное	17 264	5 610	5 576	328	28 778	16 901
	Тестовое	4 544	1 616	1 616	122	7 898	4 492
2	Тренировочное	17 554	5 709	5 690	237	29 190	17 207
	Тестовое	4 254	1 517	1 502	213	7 486	4 186
3	Тренировочное	17 220	5 600	5 565	407	28 792	16 962
	Тестовое	4 588	1 626	1 627	43	7 884	4 431
4	Тренировочное	17 813	5 724	5 686	416	29 639	17 473
	Тестовое	3 995	1 502	1 506	34	7 037	3 920
5	Тренировочное	17 381	6 261	6 251	412	30 405	17 029
	Тестовое	4 427	965	941	38	6 371	4 364

- сегментация VV: редкость этого класса потребовала создания специальной одноклассовой модели для повышения производительности за счет сосредоточения внимания исключительно на специфических характеристиках микрососудов.

Такой целенаправленный подход призван повысить эффективность сегментации за счет учета сложности и неравномерного представления различных морфологических структур.

### Стратегия обучения

Для достижения высококачественной сегментации проведена тщательная оптимизация гиперпараметров моделей. С учетом неравномерного представления различных морфологических структур в наборе данных для каждой задачи сегментации созданы отдельные наборы данных, что позволило разбить общую задачу на несколько бинарных и многоклассовых подзадач. Для каждой модели было протестировано более 350 конфигураций гиперпараметров, что обеспечило оптимальную производительность. В таблице 3 приводим полное описание гиперпараметров, исследованных в процессе настройки, а также соответствующие используемые значения.

Настройку гиперпараметров проводили на усеченном наборе данных, включавшем изображения от 40 пациентов и состоявшем из 7362 изображений, из-за высокой вычислительной сложности процесса. Предполагается, что результаты, полученные на этом подмножестве, будут представительны для всего набора данных. В качестве основной метрики оптимизации использовался Dice Similarity Coefficient (DSC), а функция потерь рассчитывалась как:

$$Loss = 1 - \frac{2 \sum (y_{true} \times y_{pred}) + \varepsilon}{\sum y_{true} + \sum y_{pred} + \varepsilon}$$

Дополнительно производительность моделей оценивали с использованием следующих метрик: точность (precision), полнота (recall), F1-мера (F1-score), Intersection over Union (IoU).

Что касается стратегии поиска гиперпараметров, мы использовали байесовский поиск, который, в отличие

Таблица 3. Гиперпараметры, используемые при оптимизации сетей

Гиперпараметр	Значение	Количество
Архитектура ИНС	U-Net, U-Net++, DeepLabV3, DeepLabV3+, FPN, LinkNet, PSPNet, PAN, MA-Net	9
Энкодер	ResNet-18, ResNet-50, ResNet-101, EfficientNet B0, EfficientNet B5, EfficientNet B7, RegNetX-200MF, RegNetX-6.4GF, RegNetY-12GF	9
Размер входного изображения, пиксели	От 512×512 до 896×896 с шагом 128×128	4
Алгоритм оптимизации	Adam, RAdam, RMSprop	3
Скорость обучения, у.е.	10 <sup>-3</sup> , 10 <sup>-4</sup> , 10 <sup>-5</sup> , 10 <sup>-6</sup>	4

от случайного или сеточного поиска, принимает обоснованные решения. Байесовская оптимизация использует вероятностную модель, чтобы определить, какие значения использовать. Кроме того, мы использовали специальную стратегию досрочного прекращения, HyperBand [31], для остановки плохо работающих конфигураций. В случае досрочного завершения HyperBand останавливает текущую конфигурацию, прежде чем приступить к работе с новым набором значений гиперпараметров. Сочетание байесовской оптимизации и досрочного завершения HyperBand образует так называемый BOHB [32] – подход, который обеспечивает более высокую вычислительную эффективность.

После настройки гиперпараметров модели были обучены на полном наборе данных с использованием оптимальных конфигураций. Обучение проводили в течение 125 эпох с учетом специфики каждой задачи сегментации.

Для оценки производительности моделей использовали 5-кратную перекрестную проверку. Набор данных был разделен на 5 частей, где 80% данных использовались для обучения, а 20% – для тестирования (табл. 2). Это позволило избежать переобучения и обеспечить надежную оценку производительности моделей.

Для увеличения размера набора данных и предотвращения переобучения применялись различные методы аугментации с использованием библиотеки Albumentations [33].

## Результаты

Проведенные эксперименты позволили оценить производительность различных моделей сегментации и предложенного ансамбля. В таблице 4 и приведенном ниже описании представлены ключевые результаты, характеризующие точность, полноту и качество сегментации морфологических компонентов АСБ:

1. *Продолжительность настройки гиперпараметров:* оптимизация гиперпараметров для FC и LC заняла наибольшее время – 712 ч, что связано с высокой сложностью представленных классов. Время оптимизации LM составило 309 ч, что обусловлено большим объемом данных и высокой точностью модели. Настройка VV заняла 103 ч, что связано с меньшим объемом данных.
2. *Производительность моделей:* U-Net++ показал наивысшую точность для сегментации LM с DSC 0,989, что свидетельствует о почти идеальном совпадении

Таблица 4. Оптимальные гиперпараметры для сегментации морфологических признаков АСБ

Параметры сети	Сосудистый просвет	Фиброзная покрышка и липидное ядро	Микрососуды
Архитектура ИНС	U-Net++	LinkNet	U-Net
Энкодер	ResNet-101	EfficientNet B7	RegNetX-6.4GF
Размер входного изображения, пиксели	512×512	896×896	896×896
Алгоритм оптимизации	RMSprop	RMSprop	RAdam
Скорость обучения, у.е.	$10^{-5}$	$10^{-5}$	$10^{-3}$
Количество параметров, М	68,000	64,400	31,900
MACs, G	249,800	9,000	158,000
Точность (Precision)	0,991	0,700	0,814
Полнота (Recall)	0,993	0,977	1,000
F1	0,989	0,617	0,784
IoU	0,979	0,488	0,695
DSC	0,989	0,617	0,784

нии предсказанных и истинных масок сегментации. Для классов FC и LC модель LinkNet достигла DSC 0,617, что указывает на умеренную точность. Архитектура U-Net достигла хороших показателей для VV – DSC 0,784, что является высоким показателем для такого небольшого набора данных.

3. *Сложность моделей:* сложность моделей оценивалась по количеству параметров и вычислительным затратам (MACs – миллиарды операций умножения-сложения). U-Net++ для сегментации LM имел 68 млн параметров и требовал 249,8 GMACs. LinkNet для FC и LC имел 64,4 млн параметров и требовал всего 9,0 GMACs, что делает его наиболее вычислительно эффективной моделью. U-Net для VV имел 31,9 млн параметров и требовал 158 GMACs.

Полученные результаты подчеркивают вариативность производительности моделей в различных задачах сегментации. U-Net++ продемонстрировала превосходную производительность при сегментации просвета сосудов, в то время как LinkNet и U-Net продемонстрировали устойчивость при сегментации фиброзной покрышки, липидного ядра и сегментации микрососудов. Данные результаты подчеркивают компромисс между точностью и сложностью модели, подчеркивая необходимость оптимизации под конкретную задачу при сегментации АСБ.

Для повышения надежности и воспроизводимости результатов обучения моделей проводилось с использованием современных подходов к валидации и настройке параметров. Это позволило обеспечить стабильность качества сегментации и снизить риск переобучения. Оценка показателей эффективности по каждому классу в процессе обучения представлена на рисунке 2.

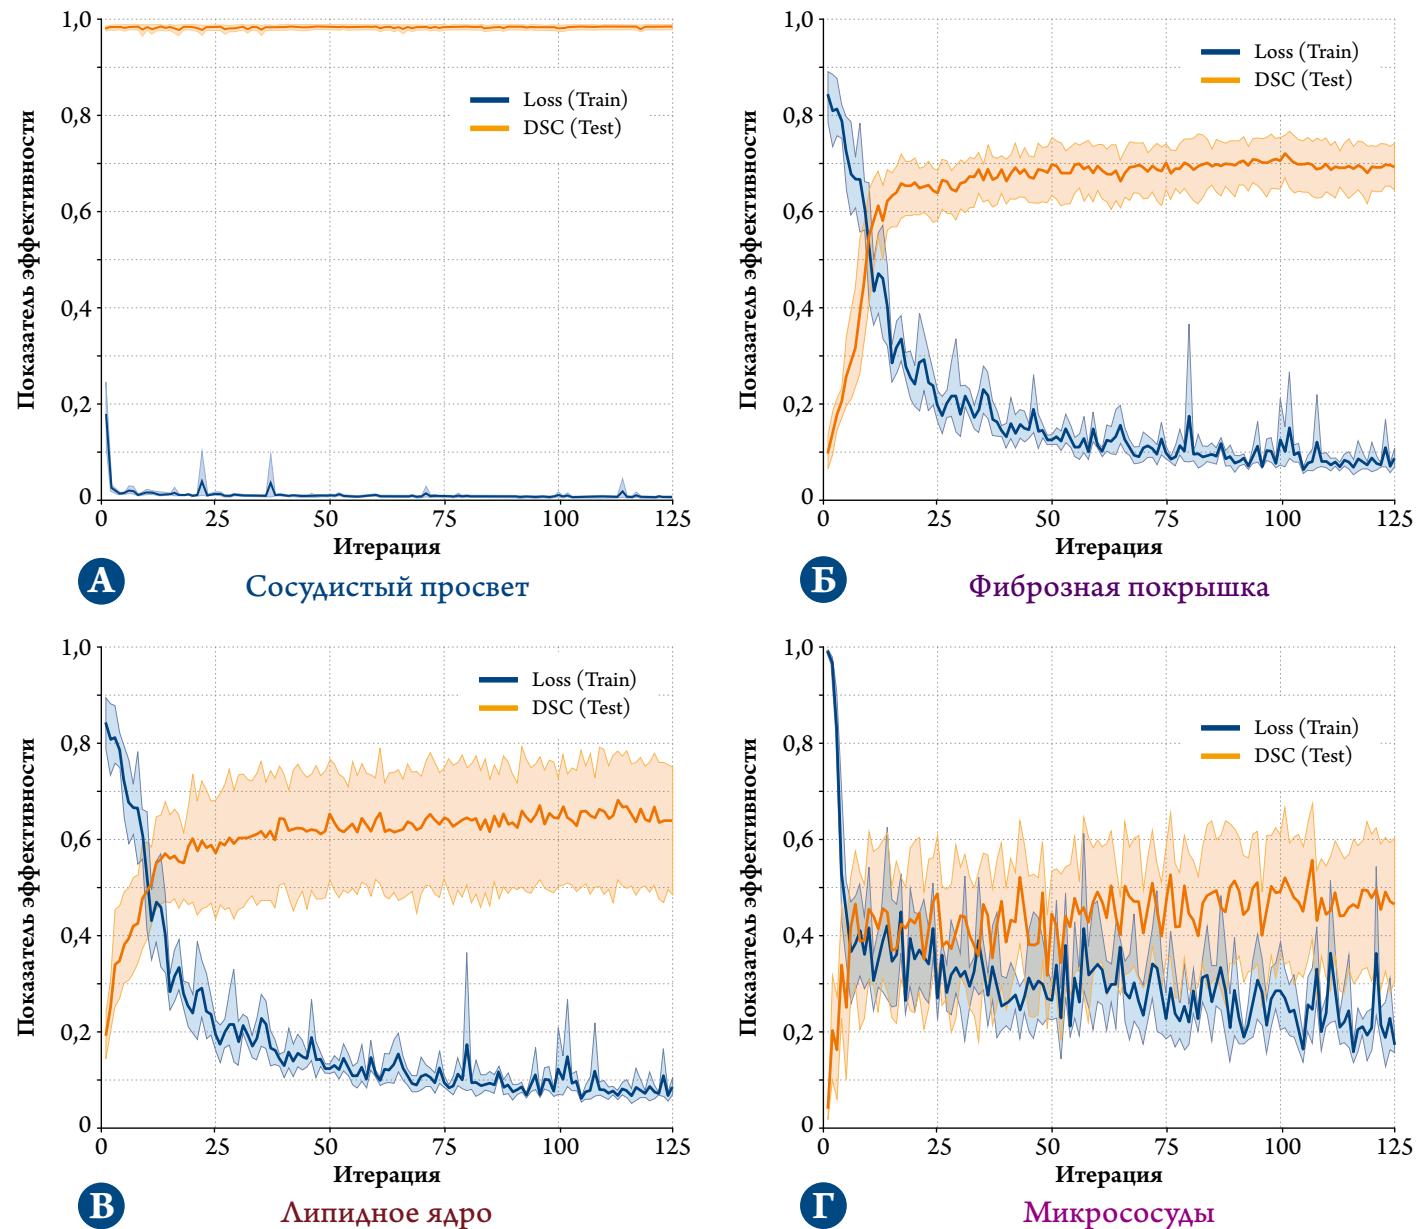
Модели сегментации LM, FC и LC продемонстрировали четкое и последовательное снижение потерь, сопровождающееся прогрессивным улучшением DSC, что свидетельствует об эффективном обучении и точном уточнении прогнозов сегментации. Модель VV демонстрировала более медленную скорость сходимости, сопровождающуюся значительными колебаниями в значениях потерь и DSC, что еще раз подчеркивает присущую сложность и проблемы, связанные с сегментацией этого признака АСБ.

Оценка показателей эффективности сегментации выявила различия в уровнях точности для всех оцениваемых морфологических компонентов. Результаты пред-

Таблица 5. Показатели эффективности сегментации для каждого морфологического признака бляшки, усредненные по 5 подмножествам во время перекрестной проверки

АСБ	Точность	Полнота	F1	IoU	DSC
Сосудистый просвет	0,986	0,988	0,987	0,975	0,987
Фиброзная покрышка	0,737	0,784	0,736	0,608	0,736
Липидное ядро	0,815	0,772	0,751	0,639	0,751
Микрососуды	0,664	0,630	0,610	0,511	0,610

Рисунок 2. Сравнительный анализ функции ошибки и DSC на этапах обучения и тестирования

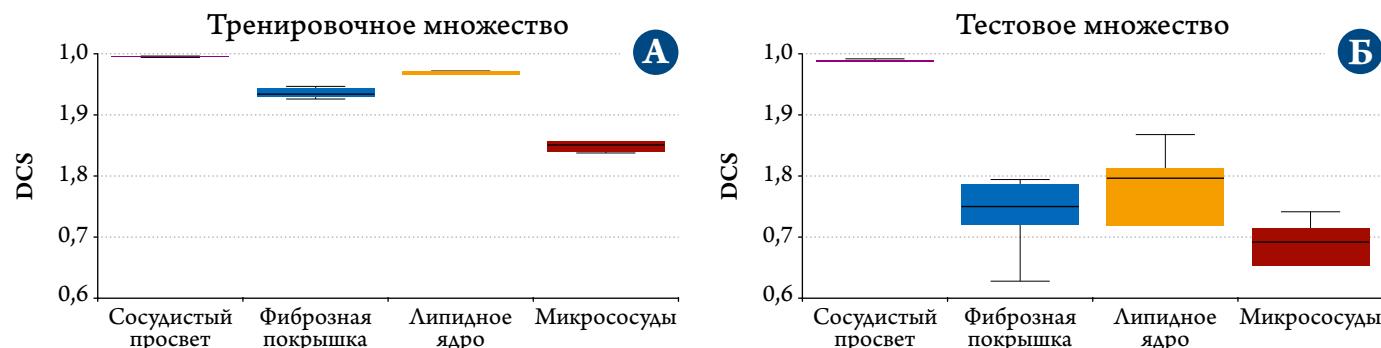


ставлены в таблице 5 и на рисунке 3. Модель сегментации просвета сосудов демонстрирует исключительную производительность, достигая DSC 0,987 и IoU 0,975. Эти показатели подчеркивают способность модели надежно и точно очерчивать структуры просвета, отмечая ее надежность и пригодность для клинических приложений, требующих точной сегментации. Напротив, модель сегментации фиброзной покрышки и липидного ядра демонстрирует надежную производительность с показателями DSC 0,736 и 0,751 соответственно. Эти результаты отражают эффективность модели в отображении сложных и запутанных границ данных структур, несмотря на трудности, связанные с их морфологией. Модель сегментации микрососудов демонстрирует умеренную эффективность, получив DSC 0,610. Хотя сегментация этого участка остается сложной из-за тонких и менее четких границ. Представ-

ленные результаты свидетельствуют о прогрессе в решении этих сложных задач. Интегрировав эти специфические для конкретной задачи модели во взвешенный ансамбль, учитывающий распространенность классов и уверенность в модели, мы достигли взвешенного DSC 0,882 для всех морфологических компонентов, что представляет собой значительное улучшение по сравнению с отдельными моделями, демонстрируя способность ансамбля гармонизировать различные архитектурные преимущества и смягчать проблемы неравномерного представления, присущие гетерогенной характеристике бляшек.

Для визуальной оценки точности сегментации на рисунке 4 мы представили три репрезентативных среза, которые иллюстрируют результаты сегментации морфологических признаков бляшек. Представленные срезы отражают прогнозируемые значения, полученные с помо-

Рисунок 3. Средняя производительность различных морфологических признаков бляшек



щью оптимального ансамбля моделей. Прогнозируемые значения сопоставляются с соответствующими «истинными аннотациями», что позволяет визуально оценить эффективность модели.

Как показано на рисунке 4, сегментация сосудистого просвета и микрососудов демонстрирует строгое совпадение с истиной, что подчеркивает эффективность ансамбля в выделении данных особенностей. Однако иногда наблюдаются незначительные расхождения в сегментации фиброзной покрышки и липидного ядра. Вероятнее всего, данные проблемы связаны с более сложной структурой и морфологией анализируемых классов. Фиброзная покрышка и липидное ядро являются компонентами ткани с диффузными и сложными границами, что затрудняет их точное определение. В частности, фиброзная покрышка представляет собой тонкий слой фиброзной ткани, покрывающий липидное ядро, и его граница может значительно различаться по текстуре и толщине. Между тем липидное ядро имеет неправильную геометрию и частые вкрапления в окружающую ткань, что еще больше усложняет его сегментацию. Эти внутренние структурные проблемы, вероятно, способствуют наблюдаемым различиям по точности сегментации. Представленные визуальные сравнения дополняют количественные показатели эффективности и позволяют понять, в каких именно областях необходимы улучшения.

## Обсуждение

Современные клинические рекомендации рекомендуют ЧКВ исключительно при поражениях, ограничивающих поток, или поражениях, связанных с острыми коронарными синдромами [34, 35]. Однако уязвимые АСБ, как ограничивающие, так и не ограничивающие поток, представляют собой значительный риск развития ССО даже при оптимальном медикаментозном лечении [36]. По данным исследований естественного течения заболевания установлено, что такие характеристики, как большое количество бляшек, уменьшение минимальной площади просвета, высокое содержание липидов и тонкая фиброзная оболочка, в значительной степени ассоциируются с ССО, обусловленными

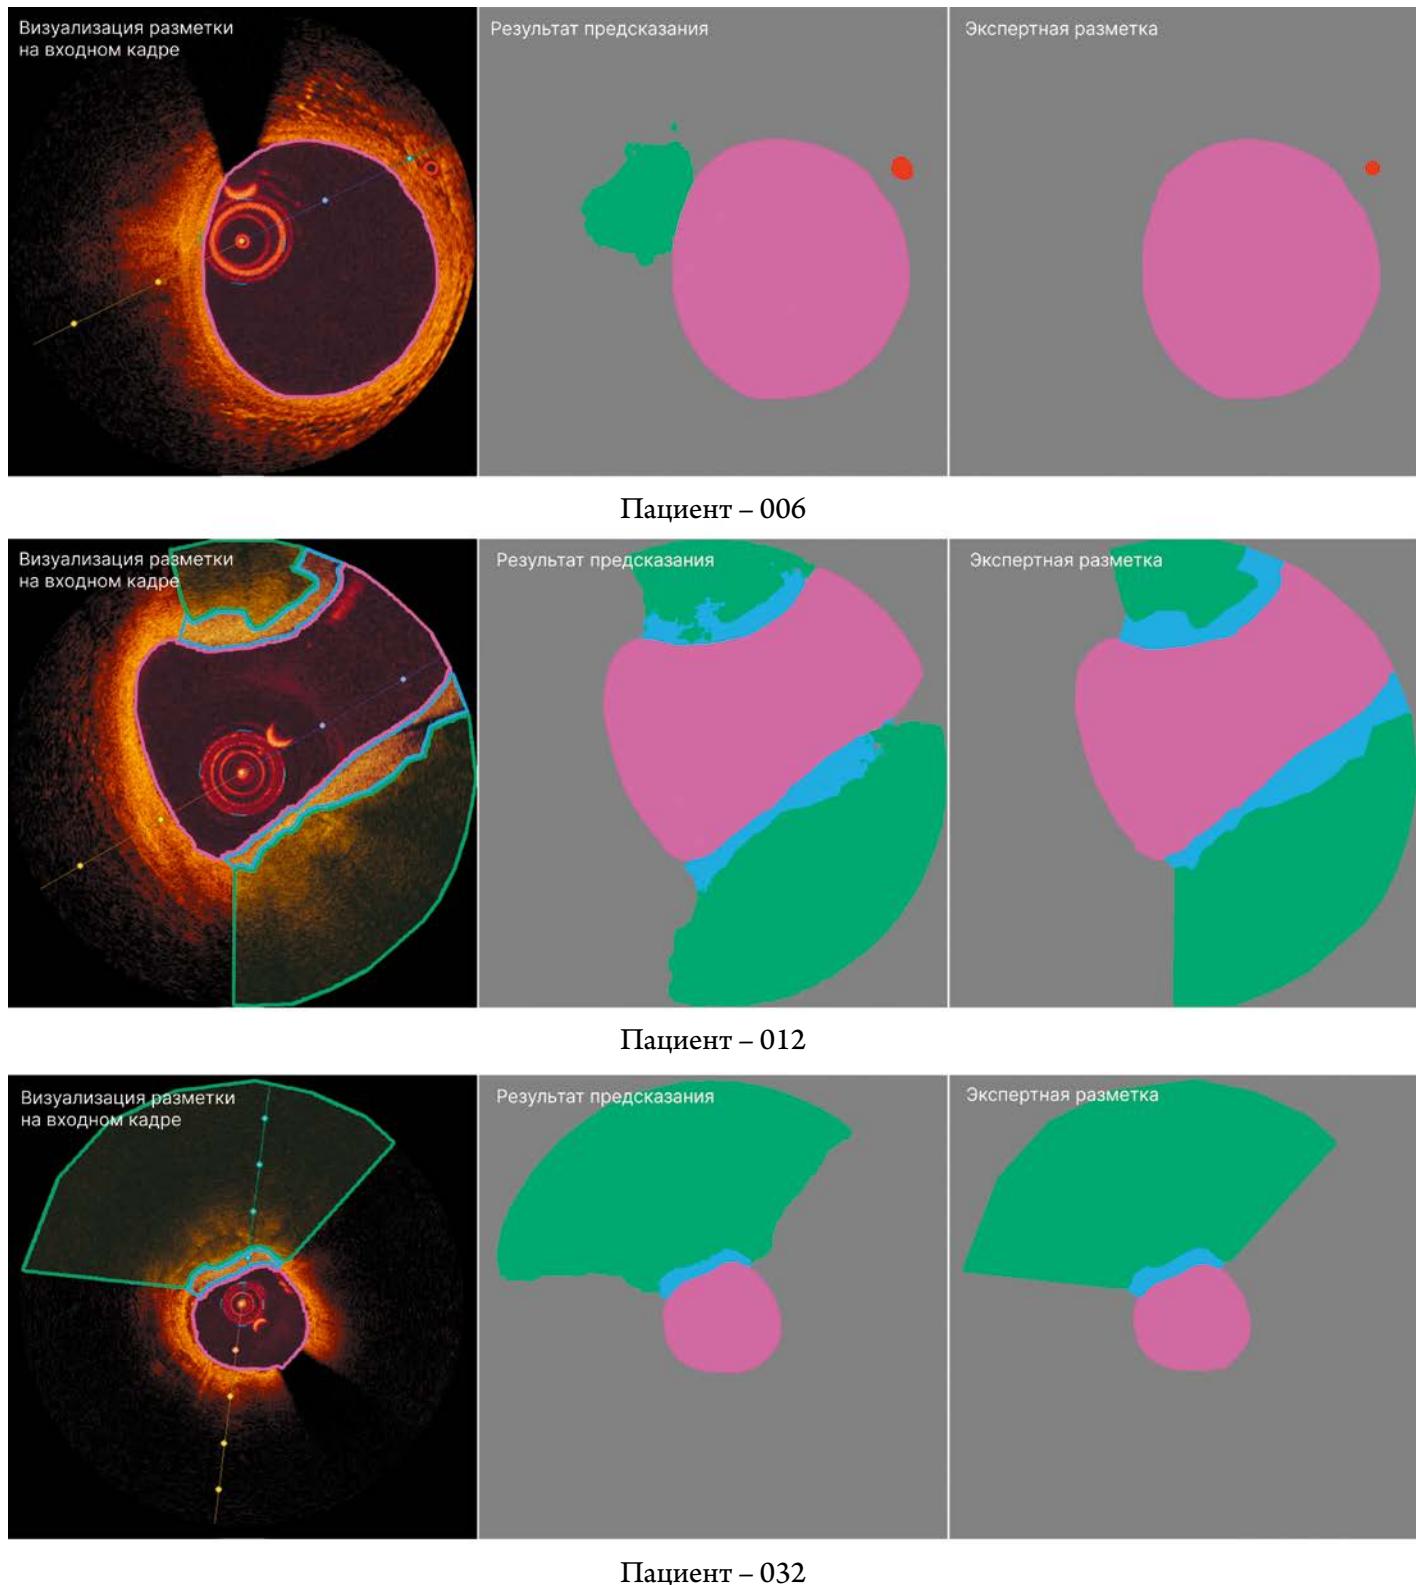
поражением, причем риск возрастает по мере увеличения числа неблагоприятных признаков [37].

Следует отметить, что уязвимость бляшек имеет динамический характер: некоторые уязвимые АСБ со временем стабилизируются без клинических осложнений, в то время как стабильные бляшки могут переходить в уязвимое состояние [38]. Это растущее понимание динамической природы уязвимости бляшек стимулировало интерес к профилактическому ЧКВ для уязвимых бляшек высокого риска. Предполагается, что механизм стентирования стабилизирует бляшки, покрывая их фиброзным колпачком и уменьшая вероятность разрыва [39].

Внутрисосудистая визуализация открывает широкие возможности для улучшения результатов ЧКВ у пациентов с заболеваниями коронарных артерий. Такие методы, как ОКТ и ВСУЗИ, обеспечивают детальную визуализацию компонентов сосудов и морфологии бляшки. Однако расхождения в интерпретации изображений между экспертами затрудняют диагностику и принятие решений [40]. Интеграция методов глубокого обучения, в частности нейронных сетей, является быстро развивающейся областью, которая может решить эти проблемы. Модели глубокого обучения, обученные на данных внутрисосудистой визуализации, могут идентифицировать морфологические элементы сосудистой стенки и оценивать уязвимость бляшек, снижая количество человеческих ошибок и ускоряя диагностические процессы.

Настоящее исследование продемонстрировало высокую эффективность гибридного подхода к сегментации АСБ в ОКТ-изображениях. Сегментация просвета сосудов достигла почти идеальной точности, и это подтверждает, что модели глубокого обучения способны надежно идентифицировать четко выраженные структуры. Умеренная точность сегментации микрососудов (DSC 0,610) связана с их малым размером, низкой контрастностью и ограниченным количеством аннотированных примеров. Это согласуется с выводами других исследователей, которые подчеркивают трудности обнаружения тонких сосудистых структур на ОКТ-изображениях. Например, J. Lee и соавт. сообщили о схожих трудностях при сегмен-

Рисунок 4. Визуальное сравнение результатов сегментации



тации микрососудов, получив средний показатель DSC  $0,73 \pm 0,10$ , что подчеркивает необходимость дальнейшего уточнения в этой области [41].

Несмотря на ограничения, предложенный гибридный подход демонстрирует значительный прогресс в автоматизации анализа ОКТ-изображений. Сочетанное использование специализированных моделей и ансамблевых

методов позволяет преодолеть сложность морфологии и неравномерное представление различных морфологических структур, что открывает путь к внедрению искусственного интеллекта в повседневную клиническую практику. Дальнейшие исследования должны быть направлены на преодоление текущих ограничений и интеграцию методов в системы поддержки принятия решений.

## Ограничения исследования

Применение методов машинного обучения для сегментации данных оптической когерентной томографии демонстрирует значительный прогресс, однако исследование имеет ряд ограничений, влияющих на его клиническую и научную применимость. Недостаточная представленность отдельных морфологических признаков, таких как микрососуды, ограничила точность их сегментации. Репрезентативность выборки ограничена пациентами из России, что снижает обобщающую способность результатов для других популяций с отличающимися факторами риска. Кроме того, высокие вычислительные затраты при обучении моделей ИНС препятствуют широкому клиническому внедрению.

## Заключение

В настоящем исследовании успешно решена задача автоматизации сегментации атеросклеротических бляшек в изображениях оптической когерентной томографии с использованием методов машинного обучения. Достигнуты высокие показатели точности для ключевых морфологических особенностей бляшек: просвет сосудов (DSC 0,987), фиброзная покрышка (DSC 0,736), липидное ядро (DSC 0,751) и микрососуды (DSC 0,610). Представленные результаты подтверждают потенциал машинного обучения для улучшения диагностической точности и эффективности анализа изображений оптической когерентной томографии.

Гибридная стратегия сегментации, предложенная в исследовании, сочетающая специализированные модели для различных классов, и строгая оптимизация гиперпараметров позволили эффективно справиться с неравномерным количеством примеров разных морфологических структур бляшек и их сложностью, что привело к значительному улучшению точности сегментации.

Интеграция моделей во взвешенный ансамбль, учитывающий распространность классов и уверенность моделей, позволила достичь взвешенного DSC 0,882, что подчеркивает важность комбинированного подхода для повышения общей точности и сбалансированности результатов.

Результаты исследования имеют важное значение для клинической практики, так как автоматизация анализа изображений оптической когерентной томографии позволяет улучшить диагностику уязвимых бляшек, стратификацию риска и принятие решений при проведении чрескожных коронарных вмешательств. Методология может быть применена не только в кардиологии, но и в других областях медицины, где требуется высокоточная сегментация сложных структур, таких как онкология и неврология.

В будущих исследованиях приоритетными будут три направления:

- 1) включение данных из более разнообразных популяций, в том числе различных этнических групп и редких подтипов бляшек, для повышения обобщающей способности моделей;
- 2) интеграция мультимодальной визуализации для более полной характеристики морфологии и состава бляшек;
- 3) оптимизация моделей для реального времени.

## Финансирование

Исследование выполнено за счет гранта Российского научного фонда № 23-75-10009 «Разработка автоматизированной системы обнаружения нестабильных бляшек с использованием оптической когерентной томографии и методов глубокого обучения».

## Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Статья поступила 23.03.2025

## СПИСОК ЛИТЕРАТУРЫ

1. Zibaeenejad F, Mohammadi SS, Sayadi M, Safari F, Zibaeeenezhad MJ. Ten-year atherosclerosis cardiovascular disease (ASCVD) risk score and its components among an Iranian population: a cohort-based cross-sectional study. *BMC Cardiovascular Disorders*. 2022;22(1):162. DOI: 10.1186/s12872-022-02601-0
2. Kochergin N.A., Kochergina A.M., Ganjukov V.I., Barbarash O.L. Vulnerable atherosclerotic plaques of coronary arteries in patients with stable coronary artery disease. *Complex Issues of Cardiovascular Diseases*. 2018;7(3):65–71. [Russian: Кочергин Н.А., Кочергина А.М., Ганюков В.И., Барбараши О.Л. Нестабильные атеросклеротические бляшки коронарных артерий у пациентов со стабильной ишемической болезнью сердца. Комплексные проблемы сердечно-сосудистых заболеваний. 2018;7(3):65-71]. DOI: 10.17802/2306-1278-2018-7-3-65-71
3. Vaduganathan M, Mensah GA, Turco JV, Fuster V, Roth GA. The Global Burden of Cardiovascular Diseases and Risk. *Journal of the American College of Cardiology*. 2022;80(25):2361–71. DOI: 10.1016/j.jacc.2022.11.005
4. Araki M, Yonetstu T, Kurihara O, Nakajima A, Lee H, Soeda T et al. Predictors of Rapid Plaque Progression. *JACC: Cardiovascular Imaging*. 2021;14(8):1628–38. DOI: 10.1016/j.jcmg.2020.08.014
5. Kochergin N.A., Kochergina A.M., Khorlamenko A.A., Ganyukov V.I., Shilov A.A., Barbarash O.L. Vulnerable atherosclerotic plaques of coronary arteries in patients with stable coronary artery disease: 12-months follow-up. *Kardiologiya*. 2020;60(2):69–74. [Russian: Кочергин Н.А., Кочергина А.М., Хорламенко А.А., Ганюков В.И., Шилов А.А., Барбараши О.Л. Нестабильные атеросклеротические бляшки коронарных артерий при стабильной ишемической болезни сердца: 12-месячное наблюдение. Кардиология. 2020;60(2):69-74]. DOI: 10.18087/cardio.2020.2.n467
6. Kowara M, Cudnoch-Jedrzejewska A. Different Approaches in Therapy Aiming to Stabilize an Unstable Atherosclerotic Plaque. *International Journal of Molecular Sciences*. 2021;22(9):4354. DOI: 10.3390/ijms22094354
7. Bentzon JF, Otsuka F, Virmani R, Falk E. Mechanisms of Plaque Formation and Rupture. *Circulation Research*. 2014;114(12):1852–66. DOI: 10.1161/CIRCRESAHA.114.302721
8. Baruś P, Modrzewski J, Gumięzna K, Dunaj P, Glód M, Bednarek A et al. Comparative Appraisal of Intravascular Ultrasound and Optical Coherence Tomography in Invasive Coronary Imaging: 2022 Update. *Journal of Clinical Medicine*. 2022;11(14):4055. DOI: 10.3390/jcm11144055

9. Kochergin N.A., Kochergina A.M. Potential of optical coherence tomography and intravascular ultrasound in the detection of vulnerable plaques in coronary arteries. *Cardiovascular Therapy and Prevention*. 2022;21(1):101–6. [Russian: Кочергин Н.А., Кочергина А.М. Возможности оптической когерентной томографии и внутрисосудистого ультразвука в выявлении нестабильных бляшек в коронарных артериях. Кардиоваскулярная терапия и профилактика. 2022;21(1):101-6]. DOI: 10.15829/1728-8800-2022-2909.
10. Kochergin N.A., Kochergina A.M. Intravascular Ultrasound Studies and the Vulnerable Atherosclerotic Plaque (Literature Review). *Medical Visualization*. 2017;21(4):82–7. [Russian: Кочергин Н.А., Кочергина А.М. Внутрисосудистый ультразвук как метод выявления нестабильных атеросклеротических бляшек коронарных артерий (обзор литературы). Медицинская визуализация. 2017;21(4):82-7]. DOI: 10.24835/1607-0763-2017-4-82-87
11. Zaghloul A, Iorgoveanu C, Balakumaran K, Balanescu DV, Donisan T. Limitations of Coronary Computed Tomography Angiography in Predicting Acute Coronary Syndrome in a Low to Intermediate-risk Patient with Chest Pain. *Cureus*. 2018;10(5):e2649. DOI: 10.7759/cureus.2649
12. Chamié D, Costa JR, Damiani LP, Siqueira D, Braga S, Costa R et al. Optical Coherence Tomography Versus Intravascular Ultrasound and Angiography to Guide Percutaneous Coronary Interventions: The iSIGHT Randomized Trial. *Circulation: Cardiovascular Interventions*. 2021;14(3):e009452. DOI: 10.1161/CIRCINTERVENTIONS.120.009452
13. Lee J, Gharaibeh Y, Zimin VN, Kim JN, Hassani NS, Dallan LAP et al. Plaque Characteristics Derived from Intravascular Optical Coherence Tomography That Predict Cardiovascular Death. *Bioengineering*. 2024;11(8):843. DOI: 10.3390/bioengineering11080843
14. Williams MC, Weir-McCall JR, Baldassarre LA, De Cecco CN, Choi AD, Dey D et al. Artificial Intelligence and Machine Learning for Cardiovascular Computed Tomography (CCT): A White Paper of the Society of Cardiovascular Computed Tomography (SCCT). *Journal of Cardiovascular Computed Tomography*. 2024;18(6):519–32. DOI: 10.1016/j.jcct.2024.08.003
15. Athanasiou LS, Bourantas CV, Riga G, Sakellarios AI, Exarchos TP, Siogkas PK et al. Methodology for fully automated segmentation and plaque characterization in intracoronary optical coherence tomography images. *Journal of Biomedical Optics*. 2014;19(2):026009. DOI: 10.1111/j.1.19.2.026009
16. Kolluru C, Prabhu D, Gharaibeh Y, Bezerra H, Guagliumi G, Wilson D. Deep neural networks for A-line-based plaque classification in coronary intravascular optical coherence tomography images. *Journal of Medical Imaging*. 2018;5(4):044504. DOI: 10.1111/1.JMI.5.4.044504
17. Lee J, Gharaibeh Y, Kolluru C, Zimin VN, Dallan LAP, Kim JN et al. Segmentation of Coronary Calcified Plaque in Intravascular OCT Images Using a Two-Step Deep Learning Approach. *IEEE Access*. 2020;8:225581–93. DOI: 10.1109/ACCESS.2020.3045285
18. Athanasiou LS, Olander ML, De La Torre Hernandez JM, Ben-Assa E, Edelman ER. A deep learning approach to classify atherosclerosis using intracoronary optical coherence tomography. *Medical Imaging 2019: Computer-Aided Diagnosis*. 2019. Av. at: <https://dspace.mit.edu/bitstream/handle/1721.1/126580/109500N.pdf>? DOI: 10.1117/12.2513078.
19. Shi P, Xin J, Zheng N. A-line-based thin-cap fibroatheroma detection with multi-view IVOCT images using multi-task learning and contrastive learning. *Journal of the Optical Society of America A*. 2022;39(12):2298. DOI: 10.1364/JOSAA.464303
20. Supervisely. Supervisely: Curate, Label and Build Production Models in One Platform. [Internet] Available at: <https://supervisely.com/>
21. Danilov VV, Litmanovich D, Proutski A, Kirpich A, Nefaridze D, Karповский A et al. Automatic scoring of COVID-19 severity in X-ray imaging based on a novel deep learning workflow. *Scientific Reports*. 2022;12(1):12791. DOI: 10.1038/s41598-022-15013-z
22. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. - Cham: Springer International Publishing; 2015. - P. 234-241. DOI: 10.1007/978-3-319-24574-4\_28.
23. Zhou Z, Rahman Siddiquee MM, Tajbakhsh N, Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation. In: *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support* - Cham: Springer International Publishing; 2018. - P. 3-11. DOI: 10.1007/978-3-030-00889-5\_1.
24. Chen L-C, Papandreou G, Schroff F, Adam H. Rethinking Atrous Convolution for Semantic Image Segmentation. *arXiv*. 2017. Av. at: <https://arxiv.org/abs/1706.05587>. DOI: 10.48550/ARXIV.1706.05587.
25. Chen L-C, Papandreou G, Kokkinos I, Murphy K, Yuille AL. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2018;40(4):834–48. DOI: 10.1109/TPAMI.2017.2699184
26. Kirillov A, He K, Girshick R, Dollár P. A unified architecture for instance and semantic segmentation. Av. at: <http://presentations.cocodataset.org/COCO17-Stuff-FAIR.pdf>.
27. Chaurasia A, Culurciello E. LinkNet: Exploiting encoder representations for efficient semantic segmentation. *2017 IEEE Visual Communications and Image Processing (VCIP)*. 2017. Av. at: <https://arxiv.org/pdf/1707.03718.pdf>. DOI: 10.1109/VCIP.2017.8305148.
28. Zhao H, Shi J, Qi X, Wang X, Jia J. Pyramid Scene Parsing Network. 2017. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). P. 6230-6239. DOI: 10.1109/CVPR.2017.660.
29. Li K, Wu Z, Peng K-C, Ernst J, Fu Y. Tell Me Where to Look: Guided Attention Inference Network. 2018. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. P. 9215-9223. DOI: 10.1109/CVPR.2018.00960.
30. Fan T, Wang G, Li Y, Wang H. MA-Net: A Multi-Scale Attention Network for Liver and Tumor Segmentation. *IEEE Access*. 2020;8:179656–65. DOI: 10.1109/ACCESS.2020.3025372
31. Li L, Jamieson K, DeSalvo G, Rostamizadeh A, Talwalkar A. Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization. *Journal of Machine Learning Research*. 2016;18(1):6765–816. DOI: 10.48550/ARXIV.1603.06560
32. Falkner S, Klein A, Hutter F. BOHB: Robust and Efficient Hyperparameter Optimization at Scale. *arXiv*. 2018. Av. at: <https://arxiv.org/pdf/1807.01774.pdf>. DOI: 10.48550/arXiv.1807.01774.
33. Buslaev A, Iglovikov VI, Khvedchenya E, Parinov A, Druzhinin M, Kalinin AA. Albumentations: Fast and Flexible Image Augmentations. *Information*. 2020;11(2):125. DOI: 10.3390/info11020125
34. Virani SS, Newby LK, Arnold SV, Bittner V, Brewer LC, Demeter SH et al. 2023 AHA/ACC/ACCP/NLA/PCNA Guideline for the Management of Patients With Chronic Coronary Disease: A Report of the American Heart Association/American College of Cardiology Joint Committee on Clinical Practice Guidelines. *Circulation*. 2023;148(9):e9–119. DOI: 10.1161/CIR.0000000000001168
35. Byrne RA, Rossello X, Coughlan JJ, Barbato E, Berry C, Chieffo A et al. 2023 ESC Guidelines for the management of acute coronary syndromes. *European Heart Journal*. 2023;44(38):3720–826. DOI: 10.1093/eurheartj/ehad191
36. Kedhi E, Berta B, Roleder T, Hermanides RS, Fabris E, IJsselmuiden AJJ et al. Thin-cap fibroatheroma predicts clinical events in diabetic patients with normal fractional flow reserve: the COMBINE OCT–FFR trial. *European Heart Journal*. 2021;42(45):4671–9. DOI: 10.1093/eurheartj/ehab433
37. Prati F, Romagnoli E, Gatto L, La Manna A, Burzotta F, Ozaki Y et al. Relationship between coronary plaque morphology of the left anterior descending artery and 12 months clinical outcome: the CLIMA study. *European Heart Journal*. 2020;41(3):383–91. DOI: 10.1093/eurheartj/ehz520
38. Kochergin N.A., Kochergina A.M., Ganyukov V.I., Barbarash O.L. Vulnerable Plaques in Patients with Stable Coronary Artery Disease. *Horizons in World Cardiovascular Research*. 2021;21:187–203
39. Park S-J, Ahn J-M, Kang D-Y, Yun S-C, Ahn Y-K, Kim W-J et al. Preventive percutaneous coronary intervention versus optimal medical therapy alone for the treatment of vulnerable atherosclerotic coronary plaques (PREVENT): a multicentre, open-label, randomised controlled trial. *The Lancet*. 2024;403 (10438):1753–65. DOI: 10.1016/S0140-6736(24)00413-6
40. Kini AS, Vengrenyuk Y, Yoshimura T, Matsumura M, Pena J, Baber U et al. Fibrous Cap Thickness by Optical Coherence Tomography In Vivo. *Journal of the American College of Cardiology*. 2017;69(6):644–57. DOI: 10.1016/j.jacc.2016.10.028
41. Lee J, Kim JN, Gomez-Perez L, Gharaibeh Y, Motairek I, Pereira GTR et al. Automated Segmentation of Microvessels in Intravascular OCT Images Using Deep Learning. *Bioengineering*. 2022;9(11):648. DOI: 10.3390/bioengineering9110648