

<https://doi.org/10.21516/2072-0076-2026-19-2-100-108>



Применение нейросетевой модели для классификации ОКТ-изображений при диагностике меланомы хориоидеи

Е.Б. Мякошина¹, С.В. Саакян^{1,2}, А.О. Укина^{3✉}, Д.Д. Гарри⁴

¹ ФГБУ «НМИЦ глазных болезней им. Гельмгольца» Минздрава России, ул. Садовая-Черногрозская, д. 14/19, Москва, 105062, Россия

² ФГБОУ ВО «Российский университет медицины» Минздрава России, ул. Долгоруковская, д. 4, Москва, 127006, Россия

³ ГБУЗ ЛО «Гатчинская клиническая межрайонная больница», ул. Рощинская, д. 15а, к. 1, Гатчина, Ленинградская обл., 188300, Россия

⁴ ООО «Искусственные сети и технологии», ул. Козлова, д. 30, Москва, 121357, Россия

Для своевременного начала лечения и улучшения витального прогноза меланомы хориоидеи (МХ) требуется ее ранняя точная диагностика. **Цель** исследования — разработка автоматизированной системы поддержки принятия врачебных решений при диагностике хориоидальных опухолей на основе изображений оптической когерентной томографии (ОКТ) с использованием технологий искусственного интеллекта (ИИ) и оценка ее работы. **Материал и методы.** Описывается процесс создания, и оценивается эффективность сверточной нейронной сети YOLO11n-cls в автоматической классификации ОКТ-изображений глазного дна на три класса: МХ, невус хориоидеи и здоровое глазное дно. **Результаты.** Для обучения и оценки модели был создан датасет из 1700 ОКТ-снимков, полученных в ФГБУ «НМИЦ ГБ им. Гельмгольца» Минздрава России за период 2014–2024 гг. Обучение проводили с применением методов аугментации и предварительно обученных на ImageNet-весов. По результатам тестирования точность модели составила 95 %. **Заключение.** Продемонстрирована перспективность применения технологий с использованием ИИ в создании программ поддержки принятия врачебных решений в офтальмологической практике.

Ключевые слова: искусственный интеллект; меланома хориоидеи; оптическая когерентная томография; нейронные сети; диагностика

Конфликт интересов: отсутствует.

Прозрачность финансовой деятельности: никто из авторов не имеет финансовой заинтересованности в представленных материалах или методах.

Для цитирования: Мякошина Е.Б., Саакян С.В., Укина А.О., Гарри Д.Д. Применение нейросетевой модели для классификации ОКТ-изображений при диагностике меланомы хориоидеи. Российский офтальмологический журнал. 2026; 19 (2): 100–8. <https://doi.org/10.21516/2072-0076-2026-19-2-100-108>

Application of a neural network model for OCT image classification in the diagnosis of choroidal melanoma

Elena B. Myakoshina¹, Svetlana V. Saakyan^{1,2}, Anastasia O. Ukina³✉, Denis D. Garri⁴

¹ Helmholtz National Medical Research Center of Eye Diseases, 14/19, Sadovaya-Chernogryazskaya St., Moscow, 105062, Russia

² The Russian University of Medicine, 4, Dolgorukovskaya St., Moscow, 127006, Russia

³ Gatchina Interdistrict Clinical Hospital, 15A, building 1, Roshchinskaya St., Gatchina, Leningrad region, 188300, Russia

⁴ Limited Liability Company "Artificial Networks and Technologies", 30, Kozlov St., Moscow, 121357, Russia
anastasiukina@yandex.ru

Early and accurate diagnosis of choroidal melanoma (CM) is required to initiate treatment in a timely manner and improve the prognosis. The purpose of the study was to develop an automated system for supporting medical decision-making in the diagnosis of choroidal tumors based on optical coherence tomography (OCT) images using artificial intelligence (AI) technologies and to evaluate its performance. Material and methods. The article describes the creation process and evaluates the effectiveness of the YOLO11n-cls convolutional neural network in the automatic classification of OCT fundus images into three classes: CM, choroidal nevus, and healthy fundus. Results. To train and evaluate the model, a dataset of 1,700 OCT images obtained at the Helmholtz National Medical Research Center of Eye Diseases over the period 2014–2024 was created. Training was performed using augmentation methods and weights pre-trained on ImageNet. According to the testing results, the accuracy of the model was 95 %. The primary limitations identified include insufficient variability in unique cases and the necessity for further external validation of the model. Conclusion. The potential of using AI-based technologies in the creation of programs to support medical decision-making in ophthalmological practice has been demonstrated.

Keywords: artificial intelligence; choroidal melanoma; optical coherence tomography; neural networks; diagnosis

Conflict of interest: there is no conflict of interest.

Financial disclosure: no author has a financial or property interest in any material or method mentioned.

For citation: Myakoshina E.B., Saakyan S.V., Ukina A.O., Garri D.D. Application of a neural network model for OCT image classification in the diagnosis of choroidal melanoma. Russian ophthalmological journal. 2026; 19 (2): 100–8 (In Russ.). <https://doi.org/10.21516/2072-0076-2026-19-2-100-108>

Диагностика меланомы хориоидеи (МХ) представляет собой сложную клиническую задачу. Раннее ее выявление требует высокой точности и часто сопряжено с дифференциальной диагностикой с невусами хориоидеи [1]. Оптическая когерентная томография (ОКТ) позволяет обнаруживать микроструктурные изменения в сосудистой оболочке и прилежащих слоях сетчатки при начальных формах МХ, независимо от степени ее пигментации, что подчеркивает важность этого метода для дифференциальной диагностики меланом и невусов хориоидеи [2–4]. Ранее описаны ОКТ-признаки начальной МХ: куполообразно изменяется профиль хориоидеи, а также появляются деструктивные изменения пигментного эпителия сетчатки, нарушается структурность фоторецепторов. Появляется отслойка нейроэпителия, сетчатка становится толще за счет появления интравитреальных депозитов, кист, отека. В отличие от меланомы, при невусах на ОКТ выявляется плоское или слегка выпуклое образование с четкими границами. Сетчатка над невусом чаще сохраняет обычную структуру, хотя может отмечаться минимальная субретинальная жидкость [4–6].

Искусственный интеллект (ИИ) и методы глубокого обучения находят все большее применение в офтальмологии, в том числе в задачах интерпретации изображений глазного дна [7]. В последние годы ученые обращаются к разработке программ на основе ИИ для анализа снимков ОКТ с различными заболеваниями. Так, в 2018 г. в работе D. Kermany и соавт. [8] продемонстрирована нейросеть для класси-

фикации снимков с возрастной макулярной дегенерацией (ВМД) и диабетическим макулярным отеком (ДМО). F. Tang и соавт. [9] акцентируют внимание на возможности использования нейросетей для анализа снимков, сделанных на ОКТ разных производителей. Нейросеть в данном исследовании определяла наличие ДМО и его тип. Подробное описание и классификация систем на основе ИИ для диагностики ВМД, центральной серозной хориоретинопатии, миопических изменений сетчатки представлены в обзоре A. Selvam и соавт. [10].

В 2022 г. под руководством Е.А. Катаевской был разработан алгоритм ИИ, предназначенный для сегментации патологических структур на ОКТ-снимках глазного дна [11]. Отечественные ученые под руководством В.В. Нероева в 2023 г. провели исследование, направленное на создание алгоритма диагностики заболеваний сетчатки по данным ОКТ с использованием ИИ. Авторы разработали прототип системы, способной диагностировать несколько заболеваний сетчатки, таких как неоваскуляризация хориоидеи, макулярный отек и множественные друзы. Для этого применяли метод обучения нейронной сети VGG16. По результатам тестирования модель продемонстрировала высокие показатели: чувствительность составила 97 %, а специфичность — 98 % [12].

Опубликованный в 2023 г. систематический обзор R. Patel и соавт. [13] отражает интерес ученых к применению технологий на основе ИИ к неинвазивным методам визуализации для раннего выявления МХ. В 2024 г. проведено

мультицентровое исследование с применением методов ИИ для оценки прогноза трансформации невуса хориоидеи в МХ [14]. В данном исследовании использовали мультимодальные данные, в том числе и снимки ОКТ. Лучший алгоритм (XGBoost, модель SAINTS) показал высокую точность: AUROC ~ 0,93 на внешней валидации. Ключевыми признаками, влияющими на решение сети, стали толщина опухоли и наличие субретинальной жидкости по данным ОКТ.

В обзорной работе К-Е. Karamanli и соавт. [15] подробно описано, что применение алгоритмов ИИ в интерпретации офтальмологических изображений при невусах и МХ приобретает все большее развитие. В данной статье указаны актуальные модели, анализируется их точность и подходы к обучению нейросетей, а также обсуждается потенциал использования в клинической практике.

Предложенные системы продемонстрировали, что нейросеть может выявлять значимые офтальмологические заболевания сетчатки на основании снимков ОКТ с уровнем надежности, близким к врачу-специалисту. Однако до настоящего времени сверточную нейронную сеть YOLO11n-cls не применяли для автоматической классификации изображений на 3 класса: МХ, невус хориоидеи и здоровое глазное дно.

ЦЕЛЬ исследования — разработка автоматизированной системы поддержки принятия врачебных решений при диагностике хориоидальных опухолей на основе ОКТ-изображений с использованием технологий ИИ и оценка ее работы.

МАТЕРИАЛ И МЕТОДЫ

Задачи исследования включали: подготовку обучающих и тестовых выборок, проведение обучения модели YOLO11n-cls, оценку возможности нейросети YOLO11n-cls в задаче классификации ОКТ-изображений сетчатки на три класса: МХ, невус хориоидеи, здоровое глазное дно.

В исследовании использовали изображения ОКТ глазного дна, предварительно классифицированные врачами-офтальмологами как здоровые, с наличием невуса или МХ. Была сформирована обучающая и тестовая выборки изображений. Для обучения применяли архитектуру YOLO11n-cls, являющуюся адаптацией сверточной нейронной сети YOLO для классификационных задач. Проводили аугментацию данных и применяли стандартные параметры обучения. В обучении нейросети использовали типичные значения следующих параметров: learning rate (скорость обучения) — определяет, насколько сильно обновляются веса модели после каждой итерации; batch size (размер батча) — количество изображений, одновременно обрабатываемых моделью перед обновлением весов; epochs (эпохи) — сколько раз нейросеть

проходит через весь обучающий набор. Авторы не подбирали уникальные или нестандартные параметры, а использовали общепринятые значения, подходящие для большинства задач классификации изображений.

Датасет. Для обучения программы с использованием ИИ был составлен датасет снимков. Изображения собирали самостоятельно, данного датасета нет в открытом доступе. Снимки ОКТ выполнялись на приборе Spectralis (Heidelberg Engineering). Для исследования был сформирован датасет изображений ОКТ, полученный на базе ФГБУ «НМИЦ ГБ им. Гельмгольца» за 10 лет (2014–2024 гг.). Архив изображений собран д. м. н. Е.Б. Мякошиной. Все пациенты подписали информированное согласие на использования данных.

Всего в датасет вошло 1700 ОКТ-снимков, разделенных на четыре диагностические категории: 500 снимков с МХ, 500 снимков с невусами хориоидеи, 500 снимков без признаков патологии, и дополнительно включены 200 снимков, локализованных в центральной зоне опухоли, для групп невусов (100) и меланом (100), что позволяло визуализировать характерные особенности каждой опухоли (рис. 1, А–В).

При подготовке данных использовали снимки 288 пациентов, распределенных следующим образом: 131 пациент с МХ, 132 пациента с невусами хориоидеи, 25 человек без признаков патологии. Таким образом, в среднем от одного пациента использовали от 15 до 20 сканов, что обеспечивало разнообразие представленных изображений. Несмотря на то, что в выборке присутствует несколько изображений от одного пациента, важно помнить, что ОКТ делает множество срезов, каждый из которых отражает разные участки глазного дна, в разных плоскостях (по горизонтали, по вертикали). Поэтому даже у одного пациента каждый срез — это уникальное изображение, которое можно использовать как отдельный обучающий пример. В дальнейшем планируется учитывать пациенториентированное разделение данных во избежание переобучения модели на индивидуальные особенности (форму сосудов, артефакты, геометрию локализации опухоли).

В рамках подготовки данных из изображений удалили вспомогательные визуальные элементы (например, фотоснимки глазного дна), а также исключили изображения с выраженными артефактами или низким качеством.

Распределение по классам проводили совместно два врача-офтальмолога (один из них — эксперт-офтальмолог, специализирующийся в офтальмоонкологии). Изображения распределены на три класса: МХ, невусы хориоидеи, здоровое глазное дно. Снимки сохраняли в формате TIFF. Для каждого изображения доступна информация о диагнозе. Данные о возрасте, поле и других клинических характеристиках не включали. Диагнозы подтверждены с помощью




Рис. 1. ОКТ-снимки глазного дна. А — меланома хориоидеи, Б — невус хориоидеи, В — здоровое глазное дно
Fig. 1. OCT images of the fundus. A — choroidal melanoma, Б — choroidal nevus, В — healthy fundus

Таблица 1. Количество изображений разных классов в обучающей, валидационной и тестовой выборках
Table 1. Number of images per class in the training, validation, and test datasets

Вид выборки Type of dataset	Снимки с меланомой хориоидеи Choroidal melanoma scans	Снимки с невусом хориоидеи Choroidal nevus scans	Снимки здорового глазного дна Healthy fundus scans	Всего
Обучающая Training	1055	1042	793	2890
Валидационная Validation	117	115	88	320
Тестовая Test	172	150	206	528
Всего	1344	1307	1087	3738

дополнительных методов визуализации и клинического обследования.

Данные разделили на обучающую, валидационную и тестовую выборки (табл. 1).

Все изображения, за исключением 206 тестовых изображений здоровых глаз, получены из архива ФГБУ «НИМЦ ГБ им. Гельмгольца». Тестовая выборка состоит из строго уникальных случаев, тогда как ОКТ-снимки в обучающей и валидационной выборках могут быть смежными срезами.

Параметры обучения нейронной сети. Для обучения модели в режиме классификации использовали нейросеть YOLO11n-cls. Обучение проводили на видеокарте RTX3080 с 16 ГБ видеопамяти с использованием батча из 16 изображений. Батч — число примеров данных, которые подаются на вход нейронной сети одновременно для обучения [16]. Входные изображения масштабировали до размера 640 × 640 пикселей, а процесс обучения длился 100 эпох. Веса предобученной на основе ImageNet модели загружали для инициализации модели. Основные гиперпараметры оптимизации включали оптимизатор AdamW с начальными значениями $lr = 0,001667$ и $momentum = 0,9$, при этом использовался параметр регуляризации $weight_decay = 0,0005$. Дополнительно использовали прогрев ($warmup_epochs = 3,0$, $warmup_momentum = 0,8$, $warmup_bias_lr = 0,1$) для стабилизации начального этапа обучения, а также dropout с коэффициентом 0,05 для борьбы с переобучением. Среди методов аугментации применялись мозаика ($mosaic = 1,0$), горизонтальное отражение ($flip_lr = 0,5$) и автоматическое аугментирование yolo ($auto_augment = randaugment$). Обучение выполнялось в детерминированном режиме для обеспечения воспроизводимости результатов. Остальные параметры были использованы по умолчанию.

РЕЗУЛЬТАТЫ

Обучение. Ход обучения отражен в таблице 2, где приведены значения времени обучения, функции потерь на тренировочном наборе (Train Loss), а также показатель top1 точности, который отражает долю случаев, когда модель на первом (самом уверенном) месте своего прогноза правильно определила класс объекта (Accuracy Top1), значения валидационной потери (Val Loss) и уровни скорости обучения — learning rate LR (pg0, pg1, pg2) для каждой из групп параметров по эпохам (Epoch).

Из представленных данных видно, что на 98-й эпохе достигнуто минимальное значение валидационной потери (0,10870) при top1 точности 0,95, что определило итоговую контрольную точку модели.

Динамика функции потерь (loss) и точности (accuracy) в процессе обучения нейросетевой модели на протяжении 100 эпох представлена на рисунке 2.

Таблица 2. Ход обучения нейросетевой модели
Table 2. Training history of the neural network model

Epoch	Train loss	Accuracy top1	Val loss	LR (pg0, pg1, pg2)
1	1.09779	0.42188	1.19102	0.000473702
2	0.96507	0.55	0.96855	0.00094063
3	0.90281	0.55	1.39443	0.00139813
...	...	...	...	...
97	0.16136	0.94063	0.11859	7.08784e-05
98	0.17314	0.95	0.10870	5.67313e-05
99	0.15737	0.94375	0.11734	4.25842e-05
100	0.15784	0.95312	0.11237	2.84371e-05




Рис. 2. Изменения функции потерь (loss) и точности (accuracy) в процессе обучения нейросетевой модели на протяжении 100 эпох
Fig. 2. Loss function and accuracy change during the training of the neural network model over 100 epochs




Рис. 3. Матрица ошибок: predicted — распределенные (предсказанные) моделью снимки по трем классам: healthy — здоровое глазное дно, melanoma — меланома хориоидеи, nevi — невус хориоидеи, true — истинное количество снимков этих классов. А — матрица ошибок в абсолютных значениях, Б — нормализованная матрица ошибок

Fig. 3. Confusion matrix where predicted denotes the distribution of images classified by the model into the three classes — healthy (healthy fundus), melanoma (choroidal melanoma), nevi (choroidal nevus) and true — denotes the actual number of images in each class. А — confusion matrix in absolute counts, Б — normalized confusion matrix

В верхнем левом углу график train/loss показывает устойчивое снижение функции потерь на обучающей выборке с начальных значений около 1,1 до финальных значений $< 0,2$, что свидетельствует о стабильном обучении без признаков дивергенции. В верхнем правом углу val/loss демонстрирует аналогичное поведение функции потерь на валидационной выборке: значение уменьшается с $\sim 1,3$ до $\sim 0,2$. Отсутствие резкого расхождения между train и val loss указывает на хорошую обобщающую способность модели и отсутствие переобучения. В нижнем левом углу metrics/accuracy_top1 отражает рост точности top-1 (т. е. доли правильных предсказаний по основному классу). Значение метрики увеличилось с 0,45 до более чем 0,92, что указывает на высокий уровень точности. В нижнем правом углу metrics/accuracy_top5 остается на уровне 1,0 на всем протяжении обучения, что означает, что истинный класс всегда входит в топ-5 предсказанных моделей вариантов. Это подтверждает высокую чувствительность модели к распознаванию правильного класса даже при наличии вероятностной неопределенности.

Тестирование. На рисунке 3, А, Б представлена матрица ошибок, отражающая результаты классификации ОКТ-снимков глазного дна, выполненной нейросетевой моделью по трем классам: «меланома хориоидеи», «невус хориоидеи» и «здоровое глазное дно». По оси абсцисс отложены истинные классы, по оси ординат — предсказанные моделью классы.

Анализ матрицы ошибок показал высокую точность классификации всех трех классов: «меланома хориоидеи», «невус хориоидеи», «здоровое глазное дно». Как показано на рисунке 3, модель корректно определила 114 (97 %) из 121 случая МХ, 107 (96 %) из 111 случаев невусов и 84 (95 %) из 88 снимков здорового глазного дна. Основные ошибки наблюдали при различении схожих классов: меланомы и невусов, а также невусов и здорового глазного дна. Нормализованная матрица (рис. 3, Б) подтверждает высокую долю верных классификаций по всем классам (> 93 %). Количество ошибок для каждого из классов не превышало 3–4 %.

Далее приведены расчеты основных характеристик работы нейросети (рис. 4, А–Д). Ассигасу (точность) — это доля правильно предсказанных классов ко всем предсказаниям. Precision (точность, положительная прогностическая ценность) — это доля

Общая точность (Accuracy):

$$\text{Accuracy} = \frac{206 + 148 + 109}{528} = \frac{463}{528} \approx 0.877 (87.7 \%)$$

А**Класс Melanoma:**

- TP = 148
- FP = 28 (из Nevi)
- FN = 1 (отнесена к Healthy) + 23 (отнесена к Nevi) = 24

$$\text{Precision}_{\text{Melanoma}} = \frac{148}{148 + 28} = \frac{148}{176} \approx 0.841 (84.1 \%)$$

$$\text{Recall}_{\text{Melanoma}} = \frac{148}{148 + 24} = \frac{148}{172} \approx 0.861 (86.1 \%)$$

$$\text{F1}_{\text{Melanoma}} = \frac{2 \times 0.841 \times 0.861}{0.841 + 0.861} = \frac{1.447}{1.702} \approx 0.851 (85.1 \%)$$

Б**Класс Nevi:**

- TP = 109
- FP = 23 (из Melanoma)
- FN = 13 (отнесены к Healthy) + 28 (отнесены к Melanoma) = 41

$$\text{Precision}_{\text{Nevi}} = \frac{109}{109 + 23} = \frac{109}{132} \approx 0.827 (82.7 \%)$$

$$\text{Recall}_{\text{Nevi}} = \frac{109}{109 + 41} = \frac{109}{150} \approx 0.727 (72.7 \%)$$

$$\text{F1}_{\text{Nevi}} = \frac{2 \times 0.827 \times 0.727}{0.827 + 0.727} = \frac{1.203}{1.554} \approx 0.773 (77.3 \%)$$

В**Класс Healthy:**

- TP = 206
- FP = 1 (из Melanoma) + 13 (из Nevi) = 14
- FN = 0

$$\text{Precision}_{\text{Healthy}} = \frac{206}{206 + 14} = \frac{206}{220} \approx 0.936 (93.6 \%)$$

$$\text{Recall}_{\text{Healthy}} = \frac{206}{206 + 0} = 1.0 (100 \%)$$

$$\text{F1}_{\text{Healthy}} = \frac{2 \times 0.936 \times 1.0}{0.936 + 1.0} = \frac{1.872}{1.936} \approx 0.966 (96.6 \%)$$

Г**Средние показатели:**

$$\text{Средняя Precision} = \frac{0.936 + 0.841 + 0.827}{3} \approx 0.868 (86.8 \%)$$

$$\text{Средняя Recall} = \frac{1.0 + 0.861 + 0.727}{3} \approx 0.862 (86.2 \%)$$

$$\text{Средняя F1 Score} = \frac{0.966 + 0.851 + 0.773}{3} \approx 0.863 (86.3 \%)$$

Д

Рис. 4. Характеристики работы нейросети, где TP = истинно положительные, FP = ложноположительные, FN = ложноотрицательные. А — общая точность, Б — расчет показателей для класса «меланома хориоидеи», В — расчет показателей для класса «невус хориоидеи», Г — расчет показателей для класса «здоровое глазное дно», Д — средние показатели

Fig. 4. Performance characteristics of the neural network, where TP = True Positive, FP = False Positive, FN = False Negative. А — accuracy, Б — calculation of metrics for the “choroidal melanoma” class, В — calculation of metrics for the “choroidal nevus” class, Г — calculation of metrics for the “healthy” class, Д — average metrics

корректных предсказаний положительного класса среди всех, которые модель отнесла к этому классу. Recall (чувствительность) — доля корректных предсказаний положительного класса среди всех реальных объектов этого класса. F1-score (гармоническое среднее между Precision и Recall) представляет собой обобщенную метрику качества классификации.

В ходе экспериментальной оценки нейросетевой модели достигнуто общее значение точности (ассиура) на уровне 87,7 %. При анализе по классам получены следующие показатели: для класса «меланома хориоидеи» точность (precision) составила 84,1 %, полнота (recall) — 86,1 %, F1-мера — 85,1 %. Для класса «невус хориоидеи» точность (precision) = 82,7 %, чувствительность (recall) = 72,7 %, F1-score = 77,3 %. Для класса «здоровое глазное дно» точность (precision) достигла 93,6 %, Чувствительность (recall) — 100,0 %, что дало F1-score в 96,6 %. Средние показатели модели оказались на уровне: Precision ≈ 86,8 %, Recall ≈ 86,2 % и F1-score ≈ 86,3 %. Полученные результаты демонстрируют высокую специфичность и чувствительность алгоритма в различении здоровых и патологических образцов, а также сбалансированность между точностью и полнотой классификации.

Высокая точность, полученная на здоровых изображениях, свидетельствует о хорошей обучаемости сети, однако требует проверки на переобученность и дополнительной валидации.

Результаты работы нейросетевой модели по классификации тестовых ОКТ-изображений представлены на рисунке 5.

ОБСУЖДЕНИЕ

В настоящее время ученые все чаще предлагают разнообразные направления внедрения ИИ в диагностические офтальмологические методы, включая применение в задачах анализа изображений фундус-фотографий и ОКТ-снимков. В статье Е.А. Каталевской и соавт. [17] подчеркнута значимость создания и развития национальных баз изображений. Один из первых вариантов создания предиктивной модели для автоматического выявления патологий на глазном дне представлен в работе отечественных авторов [18]. Исследователи разработали метод расчета комбинированного коэффициента, основанный на морфометрическом анализе сосудистого рисунка глазного дна. Данный подход заложил основы для последующей автоматизации скрининга ретиальной патологии. Технологии ИИ демонстрируют высокий потенциал в дифференциальной диагностике МХ и невусов, особенно при использовании данных фундус-фотографий и ОКТ-изображений [15]. К-Е. Karamanli и соавт. [15] подчеркивают важность стандартизации датасетов и клинической валидации моделей, что остается актуальным и в рамках нашего исследования. В последние годы активно развиваются алгоритмы ИИ, направленные на автоматическую дифференциацию хориоидальных невусов и меланом. Так, к примеру, отмечены многочисленные подходы к классификации изображений глазного дна и ОКТ с использованием CNN-моделей, демонстрирующие точность выше 90 % [15].

Для решения задачи классификации изображений ОКТ сетчатки в данной работе выбрана нейросеть YOLO. По данным литературы, этот алгоритм обладает высокой скоростью и эффективностью по сравнению с традиционными сверточными сетями, что делает его особенно пригодным для обнаружения объектов на медицинских изображениях в режиме реального времени. При этом YOLO показывает




Рис. 5. Примеры В-сканов ОКТ из тестовой выборки с истинными и предсказанными метками. Каждый блок содержит 16 случайно отобранных изображений: в левой части таблицы представлены истинные классы (голубым шрифтом — меланома хориоидеи; белым — невус хориоидеи; синим — здоровое глазное дно), в правой — метки, присвоенные нейросетью

Fig. 5. Examples of OCT-scans from the test dataset with ground-truth and predicted labels. Each panel contains 16 randomly selected images: the left grid shows the true classes (cyan: choroidal melanoma; white: choroidal nevus; blue: healthy fundus), while the right grid displays the labels assigned by the neural network

сопоставимую или более высокую точность распознавания по сравнению с другими методами, существенно выигрывая в скорости [19, 20]. Одностадийный подход YOLO к обнаружению объектов (без многоэтапных процедур) делает его исключительно подходящим для задач, требующих быстрого принятия решений, таких как медицинская диагностика [21].

Важно отметить, что при обучении данной нейросети использовали сканы ОКТ центральной части опухоли. Использование среза ОКТ-снимков именно этой зоны очень показательно и имеет большое значение для дифференциальной диагностики невуса и МХ. Необходимо также отметить, что в клинической практике недопустимо принимать клиническое решение на основании одного среза, очень важно просмотреть все возможные срезы интересующей области. Нейросетевая модель пока что ограничена анализом одного среза за раз, что не должно вводить практикующих врачей в заблуждение при использовании подобных программ в практической работе.

Несмотря на хорошие результаты классификации, имеется ограничение, связанное с недостаточной репрезентативностью обучающего датасета. Использование смежных ОКТ-срезов в обучающей и валидационной выборках приводит к тому, что модель обучается на данных, представляющих лишь ограниченное разнообразие уникальных случаев. Для расширения возможностей разработанной модели целесообразно рассмотреть два направления повышения репрезентативности датасета: это либо увеличение количества исключительно уникальных случаев, либо стандартизация формирования выборок с использованием уникальных случаев с множеством смежных срезов.

ЗАКЛЮЧЕНИЕ

Разработанная модель YOLO11n-clс продемонстрировала высокую точность в задаче классификации ОКТ-изображений по трем классам («меланома хориоидеи», «невус хориоидеи», «здоровое глазное дно»). Высокая точность достигнута при диагностике меланомы и невусов хориоидеи: для класса «меланома хориоидеи» точность (precision) составила 84,1 %, для класса «невус хориоидеи» точность (precision) = 82,7 %. Средний показатель точности равен 86,8 %, что подтверждает хорошую обучаемость модели.

Модель демонстрирует стабильную сходимость, отсутствие переобучения, высокую top-1- и практически идеальную top-5-точность. Эти характеристики делают ее подходящей для использования в задачах многоклассовой классификации в офтальмологической диагностике, особенно в условиях ограниченного числа изображений и высокой межклассовой схожести.

Данные результаты свидетельствуют о потенциальной клинической применимости модели в автоматизированной диагностике хориоидальных новообразований. Однако требует проверки ограничение, связанное с недостаточной вариативностью обучающего датасета, в перспективе целесообразно выполнить дополнительную валидацию и проверку на переобученность.

Результаты отражают известную сложность дифференциальной диагностики между доброкачественными и злокачественными образованиями хориоидеи как в клинической практике, так и при автоматизированном анализе изображений. Полученные данные подчеркивают необходимость

дальнейшего расширения и диверсификации обучающего датасета, а также потенциальную ценность мультимодального подхода с использованием дополнительных клинических и визуальных параметров. В будущем планируется создание алгоритма применения программы помощи принятия врачебных решений специалистами на основе ИИ для дифференциальной диагностики МХ и невуса хориоидеи в широкой клинической практике.

Полученные результаты свидетельствуют о перспективности применения нейросетей для автоматической диагностики внутриглазных опухолей.

Литература/References

1. Мякошина Е.Б. Начальная меланома хориоидеи и псевдомеланомы: методы дифференциальной диагностики (обзор литературы). Часть 3. *Российский офтальмологический журнал*. 2020; 13 (4): 91–8. [Myakoshina E.B. Small choroidal melanoma and pseudomelanomas: methods of differential diagnostics (literature review). Part 3. *Russian ophthalmological journal*. 2020; 13 (4): 91–8 (In Russ.)]. <https://doi.org/10.21516/2072-0076-2020-13-4-91-98>
2. Мякошина Е.Б., Саакян С.В. Оптическая когерентная томография в диагностике начальной меланомы хориоидеи. *Вестник офтальмологии*. 2020; 136 (1): 56–64. [Myakoshina E.B., Saakyan S.V. Optical coherence tomography in diagnostics of small choroidal melanoma. *Vestnik oftal'mologii*. 2020; 136 (1): 56–64 (In Russ.)]. <https://doi.org/10.17116/oftalma202013601156>
3. Бровкина А.Ф., Стояхина А.С., Мусаткина И.В. Оптическая когерентная томография в диагностике начальных меланом хориоидеи. *Вестник офтальмологии*. 2016; 132 (5): 23–34. [Brovkina A.F., Stoyukhina A.S., Musatkina I.V. Diagnostic potential of optical coherence tomography for small choroidal melanomas. *Vestnik oftal'mologii*. 2016; 132 (5): 23–34 (In Russ.)]. <https://doi.org/10.17116/oftalma2016132523-34>
4. Стояхина А.С., Мусаткина И.В. Морфогенез меланом хориоидеи в свете оптической когерентной томографии. *Вестник офтальмологии*. 2018; 134 (5–2): 186–94. [Stoyukhina A.S., Musatkina I.V. Morphogenesis of choroidal melanomas in OCT imaging. *Vestnik oftal'mologii*. 2018; 134 (5–2): 186–94 (In Russ.)]. <https://doi.org/10.17116/oftalma2018134051186>
5. Саакян С.Б., Нероев В.В., Юровская Н.Н. и др. Оптическая когерентная томография опухолеассоциированных изменений сетчатки при новообразованиях хориоидеи. *Российский офтальмологический журнал*. 2009; 2: 35–41. [Saakyan S.V., Neroev V.V., Yurovskaya N.N., et al. Optical coherence tomography of tumor-associated retinal changes in neoplasm of choroid. *Russian ophthalmological journal*. 2009; 2: 35–41 (In Russ.)].
6. Нероев В.В., Саакян С.В., Мякошина Е.Б. и др. Классификация опухолеассоциированных ретинальных изменений при увеальных новообразованиях. *Российский офтальмологический журнал*. 2010; 4: 35–9. [Neroev V.V., Saakyan S.V., Myakoshina E.B., et al. Classification of tumor-associated retinal changes in uveal tumors. *Russian ophthalmological journal*. 2010; 4: 35–9 (In Russ.)].
7. Гарри Д.Д., Саакян С.В., Хорошилова-Маслова И.П. и др. Методы машинного обучения в офтальмологии. Обзор литературы. *Офтальмология*. 2020; 17 (1): 20–31. [Garri D.D., Saakyan S.V., Khoroshilova-Maslova I.P., et al. Methods of machine learning in ophthalmology: Review. *Ophthalmology in Russia*. 2020; 17 (1): 20–31 (In Russ.)]. <https://doi.org/10.18008/1816-5095-2020-1-20-31>
8. Kermany DS, Goldbaum M, Cai W, et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*. 2018 Feb 22; 172 (5): 1122–31.e9. doi: 10.1016/j.cell.2018.02.010
9. Tang F, Wang X, Ran AR, et al. A Multitask deep-learning system to classify diabetic macular edema for different optical coherence tomography devices: A multicenter analysis. *Diabetes Care*. 2021 Sep; 44 (9): 2078–2088. doi: 10.2337/dc20-3064
10. Selvam A, Ong J, Bollepalli SC, et al. Artificial intelligence in choroid through optical coherence tomography: A comprehensive review. *Authorea Preprints*. 2023. doi: 10.36227/techrxiv.24076470.v2
11. Каталевская Е.А., Сизов А.Ю., Гилемзянова Л.И. Алгоритм искусственного интеллекта для сегментации патологических структур на сканах оптической когерентной томографии сетчатки глаза. *Российский журнал телемедицины и электронного здравоохранения*. 2022; 8 (3): 21–7. [Katalevskaya E.A., Sizov A.Yu., Gilemzianova L.I. Artificial intelligence algorithm for segmentation of pathological structures on optical coherence tomography scans. *Russian journal of telemedicine and electronic health care*. 2022; 8 (3): 21–7 (In Russ.)]. doi: 10.29188/2712-9217-2022-8-3-21-27
12. Нероев В.В., Брагин А.А., Зайцева О.В. Диагностика патологий сетчатки по снимкам оптической когерентной томографии с использованием инструментов искусственного интеллекта. *Российский офтальмологический журнал*. 2023; 16 (3): 47–53. [Neroev V.V., Bragin A.A., Zaytseva O.V. Diagnostics of retinal pathologies by optical coherence tomography images using artificial intelligence tools. *Russian ophthalmological journal*. 2023; 16 (3): 47–53 (In Russ.)]. <https://doi.org/10.21516/2072-0076-2023-16-3-47-53>
13. Patel RH, Foltz EA, Witkowski A, Ludzik J. Analysis of artificial intelligence-based approaches applied to non-invasive imaging for early detection of melanoma: a systematic review. *Cancers (Basel)*. 2023 Sep 23; 15 (19): 4694. doi: 10.3390/cancers15194694
14. Tailor PD, Kopinski PK, D'Souza HS, et al. Predicting choroidal nevus transformation to melanoma using machine learning. *Ophthalmol Sci*. 2024 Jul 20; 5 (1): 100584. doi: 10.1016/j.xops.2024.100584
15. Karamanli K-E, Maliagkani E, Petrou P, Papageorgiou E, Georgalas I. Artificial intelligence in decoding ocular enigmas: A literature review of choroidal nevus and choroidal melanoma assessment. *Applied Sciences*. 2025; 15 (7): 3565. <https://doi.org/10.3390/app15073565>
16. Ragab MG, Abdulkadir SJ, Muneer A, et al. A comprehensive systematic review of YOLO for medical object detection (2018 to 2023). *IEEE Access*. 2024; 12: 57815–536. doi: 10.1109/ACCESS.2024.3386826
17. Каталевская Е.А., Каталевский Д.Ю., Тюриков М.И., Велиева И.А., Большунов А.В. Перспективы использования искусственного интеллекта в диагностике и лечении заболеваний сетчатки. *Клиническая офтальмология*. 2022; 22 (1): 36–43. [Katalevskaya E.A., Katalevskiy D.Yu., Tyurikov M.I., Velieva I.A., Bolshunov A.V. Future of artificial intelligence for the diagnosis and treatment of retinal diseases. *Russian journal of clinical ophthalmology*. 2022; 22 (1): 36–43 (In Russ.)]. doi: 10.32364/2311-7729-2022-22-1-36-43
18. Shulga LA, Saakyan SV, Skladnev DA. Finding a uniform system of retina coefficient for early detection of initial stage of pathological changes. In: Ng EYK, Acharya UR, Tamura T, eds. *Distributed Diagnosis and Healthcare*. Vol. 3. American Scientific Publishers; 2011: 321–5.
19. Aldughayfiq B, Ashfaq F, Jhanjhi NZ, Humayun M. YOLO-Based deep learning model for pressure ulcer detection and classification. *Healthcare (Basel)*. 2023 Apr 25; 11 (9): 1222. doi: 10.3390/healthcare11091222
20. Pinto-Coelho L. How artificial intelligence is shaping medical imaging technology: A survey of innovations and applications. *Bioengineering (Basel)*. 2023 Dec 18; 10 (12): 1435. doi: 10.3390/bioengineering10121435
21. Ali ML, Zhang Z. The YOLO framework: A comprehensive review of evolution, applications, and benchmarks in object detection. *Computers*. 2024; 13 (12): 336. <https://doi.org/10.3390/computers13120336>

Вклад авторов в работу: Е.Б. Мякошина — разработка идеи и дизайна исследования, обработка и интерпретация данных, написание, редактирование и окончательное утверждение статьи для публикации; С.В. Саакян — редактирование статьи; А.О. Укина — обработка и интерпретация данных, написание и редактирование статьи; Д.Д. Гарри — обработка и интерпретация данных, написание статьи.

Author's contribution: E.B. Myakoshina — development of the idea and design of the study, data processing and interpretation, writing, editing and final approval of the article for publication; S.V. Saakyan — editing of the article; A.O. Ukina — data processing and interpretation, writing and editing of the article; D.D. Garry — data processing and interpretation, writing of the article.

Поступила: 17.06.2025. Переработана: 17.07.2025. Принята к печати: 18.07.2025
Originally received: 17.06.2025. Final revision: 17.07.2025. Accepted: 18.07.2025

ИНФОРМАЦИЯ ОБ АВТОРАХ/INFORMATION ABOUT THE AUTHORS

¹ ФГБУ «НМИЦ глазных болезней им. Гельмгольца» Минздрава России, ул. Садовая-Черногрозская, д. 14/19, Москва, 105062, Россия

² ФГБОУ ВО «Российский университет медицины» Минздрава России, ул. Долгоруковская, д. 4, Москва, 127006, Россия

Елена Борисовна Мякошина — д-р мед. наук, старший научный сотрудник отдела офтальмоонкологии и радиологии, доцент кафедры глазных болезней¹, ORCID 0000-0002-2087-7155

Светлана Владимировна Саакян — чл.-корр. РАН, д-р мед. наук, профессор, начальник отдела офтальмоонкологии и радиологии¹, заведующая учебной частью кафедры глазных болезней лечебного факультета НОИ Клинической медицины им. Н.А. Семашко², ORCID 0000-0001-8591-428X

ГБУЗ ЛО «Гатчинская клиническая межрайонная больница», ул. Рошинская, д. 15а к. 1, Гатчина, Ленинградская обл., 188300, Россия

Анастасия Олеговна Укина — врач-офтальмолог отделения офтальмологии стационара, ORCID 0009-0005-6752-9499

ООО «Искусственные сети и технологии», ул. Козлова, д. 30, Москва, 121357, Россия

Денис Дмитриевич Гарри — аспирант кафедры глазных болезней ФДПО, специалист по работе с медицинскими данными

Для контактов: Анастасия Олеговна Укина,
anastasiukina@yandex.ru

¹ Helmholtz National Medical Research Center of Eye Diseases, 14/19, Sadovaya-Chernogryazskaya St., Moscow, 105062, Russia

² The Russian University of Medicine, 4, Dolgorukovskaya St., Moscow, 127006, Russia

Elena B. Myakoshina — Dr. of Med. Sci., senior researcher of ocular oncology and radiology department, assistant professor, chair of eye diseases¹, ORCID 0000-0002-2087-7155

Svetlana V. Saakyan — Corresponding member of the Russian Academy of Sciences, Dr. of Med. Sci., professor, head of ocular oncology and radiology department¹, head of the academic department of chair of eye diseases of N.A. Semashko National Research Institute of clinical medicine², ORCID 0000-0001-8591-428X

Gatchina Interdistrict Clinical Hospital, 15A, building 1, Roshchinskaya St., Gatchina, Leningrad region, 188300, Russia

Anastasia O. Ukina — ophthalmologist, hospital ophthalmology department, ORCID 0009-0005-6752-9499

Limited Liability Company "Artificial Networks and Technologies", 30, Kozlov St., Moscow, 121357, Russia

Denis D. Garri — PhD student, chair of eye diseases of the faculty of continuing professional education, specialist in working with medical data

For contacts: Anastasiia O. Ukina,
anastasiukina@yandex.ru