

<https://doi.org/10.21516/2072-0076-2023-16-3-47-53>



Диагностика патологий сетчатки по снимкам оптической когерентной томографии с использованием инструментов искусственного интеллекта

В.В. Нероев^{1, 2}, А.А. Брагин¹ ✉, О.В. Зайцева^{1, 2}

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

² ФДПО ФГБОУ ВО «Московский государственный медико-стоматологический университет им. А.И. Евдокимова» Минздрава России, ул. Делегатская, д. 20, стр. 1, Москва, 127473, Россия

Важность раннего выявления и мониторинга заболеваний сетчатки обуславливает актуальность исследования, посвященного диагностике патологий сетчатки по снимкам оптической когерентной томографии (ОКТ) с использованием инструментов искусственного интеллекта (ИИ). **Цель работы** — разработка алгоритмов диагностики патологий сетчатки по ОКТ-снимкам при помощи методов машинного обучения. **Материал и методы.** В исследовании использован датасет (20 000 глаз), находящийся в открытом доступе в сети Интернет и включающий ОКТ-снимки здоровой сетчатки (5000 глаз) и сетчатки с тремя разными патологиями: хориоидальной неоваскуляризацией, макулярным отеком, множественными друзами (15 000 глаз). Система распознавания патологий сетчатки построена на основе обученной нейронной сети VGG16 (VGG — группа визуальной геометрии коллектива специалистов, занимающихся разработками в области ИИ). **Результаты.** Разработан и реализован на языке Python алгоритм для диагностики заболеваний сетчатки по ОКТ-снимкам на основе такого инструмента ИИ, как глубокие сверточные нейронные сети. Чувствительность и специфичность модели нейронной сети в ходе диагностики заболеваний сетчатки составили 97 и 98% соответственно. **Заключение.** Показаны высокая эффективность и потенциал методов ИИ при построении системы автоматического обнаружения патологии сетчатки в рамках разрабатываемой в НМИЦ ГБ им. Гельмгольца автоматизированной системы принятия врачебных решений. Данный сервис в перспективе может быть использован для повышения эффективности ранней диагностики и мониторинга заболеваний сетчатки в условиях ограниченной доступности первичной офтальмологической помощи на части территорий Российской Федерации, в том числе на доврачебном этапе.

Ключевые слова: патологии сетчатки; возрастная макулярная дегенерация; диабетический макулярный отек; искусственный интеллект; диагностика; сервис

Конфликт интересов: отсутствует.

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

Для цитирования: 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. <https://doi.org/10.21516/2072-0076-2023-16-3-47-53>

Diagnostics of retinal pathologies by optical coherence tomography images using artificial intelligence tools

Vladimir V. Neroev^{1, 2}, Aleksey A. Bragin¹ ✉, Olga V. Zaytseva^{1, 2}

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

² Moscow Evdokimov State Medical Stomatological University of Medicine and Dentistry, 20/1, Delegatskaya St., Moscow, 127473, Russia

bragin_aa@igb.ru

*The importance of early detection and monitoring of retinal diseases determines the relevance of the study devoted to the diagnosis of retinal pathologies by OCT images using artificial intelligence (AI) tools. The purpose is to develop algorithms for diagnosing retinal pathologies from OCT images by machine learning methods. **Material and methods.** The study used a dataset (20,000 eyes), publicly available on the Internet, which contains OCT images of healthy retina (5,000 eyes) and retina affected by three different pathologies (choroid neovascularization, macular edema, multiple drusen, 15,000 eyes). The retinal pathology recognition system is based on a trained neural network VGG16 (developed by a visual geometry group of Oxford University). **Results.** The main result of the research is the development of an algorithm, implemented on Python, for the diagnosis of retinal diseases from OCT images based on convolutional neural network AI tool. The sensitivity and selectiveness of the neural network model during the diagnosis of retinal diseases were 97 and 98%, respectively. **Conclusion.** AI methods used in the retinal pathology automatic detection system developed at the Helmholtz National Medical Research Center of Eye Diseases as part of automated medical decision-making system have been shown to have high potential and efficiency. In the future, this service can be used to improve the effectiveness of early diagnosis and monitoring of retinal diseases in conditions of reduced availability of primary ophthalmological care in some of the territories of the Russian Federation, including that provided at the pre-doctoral stage.*

Keywords: retinal pathology; age-related macular degeneration; diabetic macular edema; artificial intelligence; diagnostics; service

Conflict of interests: there is no conflict of interests.

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

For citation: 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>

Оптическая когерентная томография (ОКТ) — это неинвазивный диагностический метод, который позволяет визуализировать структуры глазного дна с высоким разрешением [1]. В настоящее время метод широко вошел в клиническую практику офтальмологов и незаменим в ходе диагностики и мониторинга большинства заболеваний глазного дна, включая наиболее распространенные инвалидизирующие патологии — возрастную макулярную дегенерацию (ВМД) и диабетический макулярный отек (ДМО) [2, 3].

Данное исследование позволяет выявить самые ранние изменения сетчатки, незаметные при осмотре глазного дна. В частности, ОКТ макулярной области в рамках рутинного исследования пациентов перед планируемой операцией факоэмульсификации катаракты высоко информативно в отношении выявления сопутствующей патологии глазного дна и прогнозирования функционального результата хирургии. В одном из исследований авторы указывают, что среди пациентов без офтальмологических заболеваний в анамнезе (за исключением катаракты) и с нормальной биомикроскопической картиной глазного дна аномальные ОКТ-изображения наблюдались в 18,6% случаев, в том числе томографические признаки ВМД были обнаружены в 8,2% глаз, макулярный отек — в 0,4% глаз [4].

В настоящее время ОКТ незаменима при диагностике и мониторинге ВМД и ДМО, в том числе в аспекте принятия

решения о начале/продолжении/возобновлении/прекращении терапии ингибиторами ангиогенеза [5].

Развитие метода томографии глаза шло по пути совершенствования технологии сканирования, повышения ее скорости и разрешающей способности прибора [6, 7]. В то же время до сих пор не достигнуто существенного прогресса в отношении программного анализа полученных изображений. Значительное и постоянно увеличивающееся число пациентов с ВМД и ДМО, необходимость их регулярного ОКТ-мониторинга обуславливают высокую нагрузку врачей-офтальмологов, требуют ежедневного анализа большого числа сканов, что повышает риск ошибки при интерпретации данных ОКТ, а также снижает доступность помощи пациентам.

В литературе представлены сообщения, посвященные применению методов искусственного интеллекта (ИИ) для анализа сканов глазного дна [8–13]. В данных работах использованы различные виды нейронных сетей. Однако современные технологии программной обработки изображений все еще сопряжены с рядом нерешенных проблем: проблемы сегментации ошибок, чрезмерной сегментации и извлечения многомасштабных признаков [14].

В связи с этим дальнейшая разработка инструментов ИИ для автоматической обработки сканов глазного дна представляется актуальной задачей.

ЦЕЛЬ работы — разработка алгоритмов диагностики патологий сетчатки по ОКТ-снимкам при помощи методов машинного обучения.

МАТЕРИАЛ И МЕТОДЫ

В исследовании использовался датасет (20 000 глаз), находящийся в открытом доступе в сети Интернет [15] и включающий в себя ОКТ-снимки здоровой сетчатки (5000 глаз)

и сетчатки с тремя разными патологиями (15 000 глаз). Примеры ОКТ-снимков без патологии и с патологиями сетчатки (неоваскуляризация хориоидеи, макулярный отек, множественные друзы) представлены на рисунках 1–4.

График распределения интенсивности пикселей одного из ОКТ-снимков представлен на рисунке 5. В ходе препроцессинга все снимки преобразованы к единому разрешению 150 на 150 пикселей. Для демонстрации эффективности




Рис. 1. Примеры ОКТ-снимков без патологии сетчатки (НОРМА)
Fig. 1. Examples of OCT images without retinal pathology (NORMAL)




Рис. 2. Примеры ОКТ-снимков с хориоидальной неоваскуляризацией (ХНВ)
Fig. 2. Examples of OCT images with choroid neovascularization (CNV)




Рис. 3. Примеры ОКТ-снимков с диабетическим макулярным отеком (ДМО)
Fig. 3. Examples of OCT images with diabetic macular edema (DME)




Рис. 4. Примеры ОКТ-снимков с множественными друзами (ДРУЗЫ)
Fig. 4. Examples of OCT images with multiple druzes (DRUSEN)

применения методов ИИ, особенно в условиях, когда доступ к наборам размеченных высококачественных медицинских изображений затруднен, мы ограничились частью датасета объемом 1000 снимков ОКТ, которая была разделена на две выборки: для обучения нейронной сети (200 снимков здоровой сетчатки и 600 снимков сетчатки с патологиями) и для тестирования качества модели (50 снимков здоровой сетчатки и 150 снимков сетчатки с патологиями).

Перед началом обучения модели нейронной сети датасет был сбалансирован с использованием метода SMOTE (метод синтетической передискретизации меньшинства, алгоритм предварительной обработки данных, используемый для устранения дисбаланса классов в наборе данных). График балансировки датасета представлен на рисунке 6.

РЕЗУЛЬТАТЫ

Модель нейронной сети с дообучением на отдельных слоях показана на рисунке 7. На первом этапе обучения использовались предобученные модели VGG16 [16] с оптимизатором Adam. На завершающем этапе отдельные слои модели дообучались для повышения показателей чувствительности и специфичности. В ходе первой итерации обучения принадлежность к классу задавалась случайным образом, а далее проверялось его соответствие истинному значению, корректировались весовые коэффициенты в случае несовпадения и процесс повторялся. Таким образом, обучение нейронной сети превратилось в автоматический итерационный процесс поиска весовых коэффициентов на каждом уровне преобразования входного массива данных, в результате которого удалось спрогнозировать принадлежность изображения к тому или иному классу (классам, характеризующим наличие признаков заболевания или их отсутствие) [17].

В ходе обучения модели были достигнуты значения метрик чувствительности и специфичности 97 и 98% соответственно, что продемонстрировало высокую эффективность применения трансферного глубокого обучения даже на небольших наборах медицинских данных. Примеры графиков изменения специфичности и ошибки для учебного и тестового набора изображений в процессе обучения модели нейронной сети показаны на рисунке 8.

Анализ данных графиков позволяет сделать вывод о высоком потенциале методов машинного обучения для распознавания патологий сетчатки. Подтверждением высокой эффективности обученной модели нейронной сети явля-




Рис. 5. График распределения интенсивности пикселей ОКТ-снимка
Fig. 5. Graph of the intensity distribution of pixels of an OCT image

{0: 'Normal', 1: 'CNV', 2: 'DME', 3: 'DRUSEN'}




Рис. 6. Балансировка датасета
Fig. 6. Balancing a dataset

ется и матрица ошибок, демонстрирующая распределение прогнозируемых и фактических значений предсказаний по четырем классам классификации. Матрица ошибок классификации представлена на рисунке 9, по ее значениям можно сделать вывод об успешности обучения модели нейронной сети. Матрица содержит значения истинно положительных, истинно отрицательных, ложно положительных и ложно от-

рицательных предсказаний, элементы по диагонали слева направо сверху вниз являются значениями правильно предсказанных значений, а элементы вне этой диагонали характеризуют незначительные ошибки предсказаний.

Еще одним способом оценки результатов исследования является метод AUC-ROC (AUC — площадь под кривой, ROC — рабочая характеристика приемника) [16], согласно которому эффективность обучения модели проверяется анализом площади под кривой ROC (рис. 10), являющейся метрикой способности модели различать классы (типы патологий). На рисунке 10 представлен график кривой ROC, анализ площади под которой позволяет сделать вывод о высокой эффективности модели нейронной сети, обученной для распознавания трех патологий сетчатки. Кривая ROC представляет собой зависимость чувствительности модели (доли правильно идентифицированных положительных результатов диагностики) от ее специфичности (доли правильно идентифицированных отрицательных результатов диагностики), а значение площади под кривой стремится к единице, что еще раз подтверждает высокую эффективность результатов проведенного исследования.

Трансферное обучение, основанное на дообучении на отдельных слоях предобученной модели нейронной сети, позволило достичь высокие значения не только чувствительности, но и специфичности модели как способности не определять патологию при ее отсутствии.

ОБСУЖДЕНИЕ

В ходе проведенного исследования продемонстрирована возможность трансферного обучения для построения высокоэффективной системы распознавания признаков патологий сетчатки по снимкам ОКТ. Полученные значения чувствительности и специфичности модели нейронной сети при распознавании трех патологий сетчатки составили 97 и 98% соответственно. Настоящее исследование продемонстрировало высокий потенциал трансферного обучения для распознавания нескольких патологий сетчатки и заложило фундамент для разрабатываемой в НМИЦ ГБ им. Гельмгольца автоматизированной системы принятия врачебных решений.

Исследования в области использования машинного обучения для диагностики патологий сетчатки уже проводились за рубежом и в России [8–12]. Используемые в них подходы направлены на диагностику отдельных патологий.

Model: "model"

Layer (type)	Output Shape	Param #	Connected to
input_2 (InputLayer)	[(None, 150, 150, 3)]	0	[]
conv2d (Conv2D)	(None, 74, 74, 32)	864	['input_2[0][0]']
batch_normalization (BatchNormalization)	(None, 74, 74, 32)	96	['conv2d[0][0]']
activation (Activation)	(None, 74, 74, 32)	0	['batch_normalization[0][0]']
conv2d_1 (Conv2D)	(None, 72, 72, 32)	9216	['activation[0][0]']
batch_normalization_1 (BatchNormalization)	(None, 72, 72, 32)	96	['conv2d_1[0][0]']
activation_1 (Activation)	(None, 72, 72, 32)	0	['batch_normalization_1[0][0]']
conv2d_2 (Conv2D)	(None, 72, 72, 64)	18432	['activation_1[0][0]']
batch_normalization_2 (BatchNormalization)	(None, 72, 72, 64)	192	['conv2d_2[0][0]']
activation_2 (Activation)	(None, 72, 72, 64)	0	['batch_normalization_2[0][0]']
max_pooling2d (MaxPooling2D)	(None, 35, 35, 64)	0	['activation_2[0][0]']
conv2d_3 (Conv2D)	(None, 35, 35, 80)	5120	['max_pooling2d[0][0]']
batch_normalization_3 (BatchNormalization)	(None, 35, 35, 80)	240	['conv2d_3[0][0]']
activation_3 (Activation)	(None, 35, 35, 80)	0	['batch_normalization_3[0][0]']
conv2d_4 (Conv2D)	(None, 33, 33, 192)	138240	['activation_3[0][0]']
...			
activation_87 (Activation)	(None, 3, 3, 384)	0	['batch_normalization_87[0][0]']
activation_88 (Activation)	(None, 3, 3, 384)	0	['batch_normalization_88[0][0]']
activation_91 (Activation)	(None, 3, 3, 384)	0	['batch_normalization_91[0][0]']
activation_92 (Activation)	(None, 3, 3, 384)	0	['batch_normalization_92[0][0]']
batch_normalization_93 (BatchNormalization)	(None, 3, 3, 192)	576	['conv2d_93[0][0]']
activation_85 (Activation)	(None, 3, 3, 320)	0	['batch_normalization_85[0][0]']
mixed9_1 (Concatenate)	(None, 3, 3, 768)	0	['activation_87[0][0]', 'activation_88[0][0]']
concatenate_1 (Concatenate)	(None, 3, 3, 768)	0	['activation_91[0][0]', 'activation_92[0][0]']
activation_93 (Activation)	(None, 3, 3, 192)	0	['batch_normalization_93[0][0]']
mixed10 (Concatenate)	(None, 3, 3, 2048)	0	['activation_85[0][0]', 'mixed9_1[0][0]', 'concatenate_1[0][0]', 'activation_93[0][0]']
flatten (Flatten)	(None, 18432)	0	['mixed10[0][0]']
dropout (Dropout)	(None, 18432)	0	['flatten[0][0]']
dense (Dense)	(None, 4)	73732	['dropout[0][0]']

 Total params: 21,876,516
 Trainable params: 73,732
 Non-trainable params: 21,802,784

Рис. 7. Модель нейронной сети VGG16 с дообучением на отдельных слоях
Fig. 7. VGG 16 neural network model with additional training on separate layers

Настоящее исследование, в отличие от существующих, направлено на разработку прототипа доступного и эффективного web-сервиса для многоклассовой диагностики нескольких патологий сетчатки одновременно на основе трансфер-




Рис. 8. Графики изменения метрики и потерь в зависимости от количества эпох обучения

Fig. 8. Graphs of changes in metrics and losses depending on the number of training epochs

ного переобучения нейронной сети VGG16, позволяющего повысить скорость, мобильность диагностики и сократить нагрузку на бюджет в будущем в рамках разрабатываемой в НМИЦ ГБ им. Гельмгольца автоматизированной системы принятия врачебных решений. Достоверность оценок чувствительности и специфичности настоящего исследования не вызывает сомнений, так как проверена в ручном режиме опытными офтальмологами НМИЦ ГБ им. Гельмгольца.

ЗАКЛЮЧЕНИЕ

Проведенное исследование продемонстрировало высокий потенциал методов машинного обучения, способных с высокой чувствительностью отслеживать миллионы признаков заболевания за считанные секунды. Использование ИИ при анализе сканов ОКТ имеет очевидные перспективы широкого внедрения в клиническую практику Российской Федерации. Высокоэффективная система распознавания признаков патологий сетчатки по снимкам ОКТ может использоваться в качестве скрининга пациентов на доврачебном этапе оказания медицинской помощи, в ходе профилактических осмотров или диспансеризации определенных групп населения, в том числе пациентов с сахарным диабетом. Внедрение макулярной ОКТ с обработкой данных методом ИИ в качестве теста перед операцией по удалению катаракты позволит выявить патологию на ранней стадии, спрогнозировать результат хирургии и разработать дальнейшую тактику ведения пациента.

При условии использования ИИ для обработки снимков процесс сканирования сетчатки может быть выполнен техническим или средним медицинским персоналом, врачом общей практики. Выявление каких-либо изменений позволит вовремя направить пациента к офтальмологу для получения квалифицированной помощи. Данная технология в перспективе может снизить нагрузку на бюджет за счет частичной замены высококвалифицированных кадров ИИ. Прототип web-сервиса для диагностики патологии сетчатки




Рис. 9. Матрица ошибок классификации

Fig. 9. Confusion Matrix




Рис. 10. График кривой ROC

Fig. 10. ROC curve graph

по данным ОКТ на основе нейронной сети VGG16 в дальнейшем станет основой автоматизированной системы принятия врачебных решений, информативным инструментом скрининга и мониторинга патологии сетчатки.

Перспективным представляется расширение возможностей технологии в направлении программного анализа снимков ОКТ центральной зоны глазного дна для верификации типа патологической жидкости (интра-, субретинальная либо жидкость под пигментным эпителием), состояния слоев нейроэпителия (наличие дезорганизации линии эллипсоидов, наружной пограничной мембраны, симптома DRIL), наличия рубцовых или атрофических изменений, отложения гиперрефлективных фокусов и т.д. Данная функция может

быть информативным инструментом диагностики и мониторинга заболеваний глазного дна, прогноза зрительных функций, выбора тактики ведения больного.

Литература/References

1. Monroy GL, Won J, Spillman DR, Dsouza R, Boppart SA. Clinical translation of handheld optical coherence tomography: practical considerations and recent advancements. *J Biomed Opt.* 2017; 22 (12): 1–30. doi: 10.1117/1.JBO.22.12.121715
2. Das R, Spence G, Hogg RE, Stevenson M, Chakravarthy U. Disorganization of inner retina and outer retinal morphology in diabetic macular edema. *JAMA Ophthalmol.* 2018; 136 (2): 202–8. doi: 10.1001/jamaophthalmol.2017.6256
3. Schneider EW, Fowler SC. Optical coherence tomography angiography in the management of age-related macular degeneration. *Curr Opin Ophthalmol.* 2018; 29 (3): 217–25. doi: 10.1097/ICU.0000000000000469
4. Herranz-Cabarcos A, Vega-López Z, Salas-Fandos O, et al. Macular optical coherence tomography for screening of pathology prior to cataract surgery: An approach based on tele-evaluation. *Eur J Ophthalmol.* 2022; 32 (6): 3433–7. doi: 10.1177/11206721221080818
5. Макулярная дегенерация возрастная. Клинические рекомендации. Доступно на: https://cr.minzdrav.gov.ru/recomend/114_2 (дата обращения 10 февр. 2023). [Age-related macular degeneration. Clinical recommendations. Available at: https://cr.minzdrav.gov.ru/recomend/114_2. (Accessed 10. Feb. 2023).
6. Vira J, Marchese A, Singh RB, Agarwal A. Swept-source optical coherence tomography imaging of the retinohoroid and beyond. *Expert Rev Med Devices.* 2020; 17 (5): 413–26. doi: 10.1080/17434440.2020.1755256
7. Fujimoto J, Swanson E. The development, commercialization, and impact of optical coherence tomography. *Invest. Ophthalmol. Vis. Sci.* 2016; 57 (9): OCT1–OCT13. doi: 10.1167/iovs.16-19963
8. Hu J, Chen Y, Yi Z. Automated segmentation of macular edema in OCT using deep neural networks. *Med. Image Anal.* 2019; 55: 216–27. doi: 10.1016/j.media.2019.05.002
9. Lu D, Heisler M, Sieun Lee S, et al. Deep-learning based multiclass retinal fluid segmentation and detection in optical coherence tomography images using

a fully convolutional neural network. *Med Image Anal.* 2019; 54: 100–10. doi: 10.1016/j.media.2019.02.011

10. Soomro TA, Afifi A, Zheng L, Soomro S, et al. Deep learning models for retinal blood vessels segmentation: a review. *IEEE Access.* 2019; 7: 71696–717. doi: 10.1109/ACCESS.2019.2920616
11. Feng Z, Yang J, Yao L, et al. Deep retinal image segmentation: a FCN-based architecture with short and long skip connections for retinal image segmentation. *ICONIP.* Springer; 2017: 713–22. Available at: https://www.researchgate.net/publication/320580185_Deep_Retinal_Image_Segmentation_A_FCN-Based_Architecture_with_Short_and_Long_Skip_Connections_for_Retinal_Image_Segmentation (Accessed 03. Nov. 2022).
12. Asgar R, Waldstein S, Schlanitz F, et al. U-Net with spatial pyramid pooling for drusen segmentation in optical coherence tomography. *OMIA:* Springer; 2019: 77–85 Available at: <https://arxiv.org/pdf/1912.05404v1.pdf> (Accessed 06. Jul. 2022).
13. Нероев В.В., Брагин А.А., Зайцева О.В. Разработка прототипа сервиса для диагностики диабетической ретинопатии по снимкам глазного дна с использованием методов искусственного интеллекта. *Национальное здравоохранение.* 2021; 2 (2): 64–72. [Neroev V.V., Bragin A.A., Zaytseva O.V. Development of a prototype service for the diagnosis of diabetic retinopathy based on fundus photos using artificial intelligence methods. *National Health Care (Russia).* 2021; 2 (2): 64–72 (In Russ.).] doi: 10.47093/2713-069X.2021.2.2.64-72
14. Esfahani EN, Daneshmand PG, Rabbani H, Plonka G. Automatic classification of macular diseases from OCT images using CNN guided with edge convolutional layer. *Annu Int. Conf. IEEE Eng. Med. Biol. Soc.* 2022; 2022: 3858–61. doi: 10.1109/EMBC48229.2022.9871322
15. Kermany DS, Goldbaum M, Cai W, et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell.* 2018; 172 (5): 1122–31. doi: <https://doi.org/10.1016/j.cell.2018.02.010>. Available at: [http://www.cell.com/cell/fulltext/S0092-8674\(18\)30154-5](http://www.cell.com/cell/fulltext/S0092-8674(18)30154-5) (Accessed 20.01.2023).
16. Джулли А., Пал С. Библиотека Keras — инструмент глубокого обучения. Москва: ДМК Пресс; 2017. [Julli A., Pal S. Deep learning with Keras. Moscow: DMK Press; 2017 (In Russ.).]
17. Nielsen MA. Neural networks and deep learning. *Determination Press.* 2018. Available at: <https://static.latexstudio.net/article/2018/09/12/neuralnetworksanddeeplearning.pdf> (Accessed (03. Jan.2023).

Вклад авторов в работу: В.В. Нероев — формулировка идеи, цели и задач исследования, окончательное редактирование и утверждение рукописи для публикации; А.А. Брагин — статистическая обработка, разработка и анализ инструментов распознавания патологий сетчатки, написание статьи; О.В. Зайцева — сбор и систематизация данных для научной работы, лабораторная проверка датасета на достоверность и его разметка, написание и редактирование статьи.

Authors' contribution: V.V. Neroev — formulation of the idea, goals and objectives of the research, final editing and approval of the article for publication; A.A. Bragin — statistical processing, service prototype development, writing of the article; O.V. Zaytseva — data collection and systematization of scientific work, laboratory validation of the dataset and its markup, writing and editing of the article.

Поступила: 07.02.2023. Переработана: 13.02.2023. Принята к печати: 14.02.2023

Originally received: 07.02.2023. Final revision: 13.02.2023. Accepted: 14.02.2023

ИНФОРМАЦИЯ ОБ АВТОРАХ/INFORMATION ABOUT THE AUTHORS

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

² ФДПО ФГБОУ ВО «Московский государственный медико-стоматологический университет им. А.И.Евдокимова» Минздрава России, ул. Десятская, д. 20, стр. 1, Москва, 127473, Россия

Владимир Владимирович Нероев — д-р мед. наук, профессор, академик РАН, директор¹, заведующий кафедрой глазных болезней², ORCID 0000-0002-8480-0894

Алексей Александрович Брагин — канд. техн. наук, начальник отдела информационных технологий¹, ORCID 0000-0002-5331-632X

Ольга Владимировна Зайцева — канд. мед. наук, заместитель директора по организационно-методической работе¹, доцент кафедры глазных болезней², ORCID 0000-0003-4530-553X

Для контактов: Алексей Александрович Брагин, bragin_aa@igb.ru

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

² Moscow Evdokimov State Medical Stomatological University of Medicine and Dentistry, 20/1, Delegatskaya St., Moscow, 127473, Russia

Vladimir V. Neroev — Dr. of Med. Sci., professor, academician of the Russian Academy of Science, director¹, head of chair of eye diseases², ORCID 0000-0002-8480-0894

Aleksey A. Bragin — Cand. of Tech. Sci., head of the information technology department¹, ORCID 0000-0002-5331-632X

Olga V. Zaytseva — Cand. of Med. Sci., deputy director¹, associate professor of chair of eye diseases², ORCID 0000-0003-4530-553X

For contacts: Aleksey A. Bragin, bragin_aa@igb.ru