

ПРИМЕНЕНИЕ НЕЙРОСЕТЕЙ В ДИАГНОСТИКЕ ДИАБЕТИЧЕСКОЙ РЕТИНОПАТИИ

Э. Р. Добров

Новосибирский государственный университет экономики
и управления, Новосибирск, Россия
sib.2020@bk.ru

Аннотация. *Актуальность и цели.* Одним из серьезных последствий заболевания сахарным диабетом является негативное воздействие на зрительную систему. Целью работы является обзор источников, посвященных задаче диагностирования диабетической ретинопатии по изображениям глаза с помощью нейронных сетей. *Материалы и методы.* Рассмотрено использование современных методов, подходов и алгоритмов на таких этапах, как сбор и подготовка наборов данных, предварительная обработка данных, задача распознавания изображений, трансферное обучение, сравнение методов, ансамбли моделей, разработка системы. Обозначены возможные перспективные дальнейшие шаги в будущих исследованиях. *Результаты.* В процессе анализа публикаций о методах диагностирования диабетической ретинопатии по изображениям глаза на основе нейронных сетей определены следующие направления для улучшения существующих результатов: увеличение наборов данных изображений, методы предварительной обработки изображений, интерпретация модели нейронной сети, вычислительная мощность алгоритмов для внедрения на мобильных устройствах, задачи классификации и сегментации поражений глаза, ложноотрицательные и ложноположительные диагнозы, ансамбли моделей, применение рекуррентных и капсульных нейросетей. *Выводы.* По итогам исследования определены направления по улучшению достижений в задаче распознавания изображений глаза для диагностирования диабетической ретинопатии.

Ключевые слова: анализ изображений, нейронные сети, диабетическая ретинопатия

Благодарности: автор данной статьи выражает глубокую благодарность рецензентам редакции журнала, которые помогли подготовить рукопись к публикации.

Для цитирования: Добров Э. Р. Применение нейросетей в диагностике диабетической ретинопатии // Модели, системы, сети в экономике, технике, природе и обществе. 2022. № 2. С. 90–105. doi:10.21685/2227-8486-2022-2-7

THE USE OF NEURAL NETWORKS IN THE DIAGNOSIS OF DIABETIC RETINOPATHY

E.R. Dobrov

Novosibirsk State University of Economics and Management, Novosibirsk, Russia
sib.2020@bk.ru

Abstract. *Background.* One of the serious consequences of diabetes is the negative impact on the visual system. The aim of the work is to review the sources devoted to the task of diagnosing diabetic retinopathy from eye images using neural networks. *Materials and methods.* The use of modern methods, approaches and algorithms at such stages as data collection and preparation, data preprocessing, image recognition task, transfer training, comparison of methods, ensembles of models, system development is considered. Possible promising further steps in the future research are outlined. *Results.* In the process of analyzing publications on methods of diagnosing diabetic retinopathy from eye images based on neural networks, the following areas were identified to improve the existing results: increasing image data sets, image preprocessing methods, interpretation of the neural network model, computational power of algorithms for implementation on mobile devices, classification and segmentation tasks of eye lesions, false-negative and false-positive diagnoses, ensembles of models, the use of recurrent and capsule neural networks. *Conclusions.* Based on the results of the study, the directions for improving the achievements in the task of eye image recognition for the diagnosis of diabetic retinopathy were identified.

Keywords: image analysis, neural networks, diabetic retinopathy

Acknowledgements: the author of this article expresses deep gratitude to the reviewers of the editorial board of the journal who helped prepare the manuscript for publication.

For citation: Dobrov E.R. The use of neural networks in the diagnosis of diabetic retinopathy. *Modeli, sistemy, seti v ekonomike, tekhnike, prirode i obshchestve* = *Models, systems, networks in economics, technology, nature and society*. 2022;(2):90–105. (In Russ.). doi:10.21685/2227-8486-2022-2-7

Введение

Согласно проведенным исследованиям за последние двадцать лет численность населения, заболевшего сахарным диабетом, продолжает увеличиваться. Сахарный диабет воздействует на многие системы организма, в том числе на зрительную систему. Ухудшение зрения, наступающее из-за поражения сосудов сетчатки глаза, называется диабетической ретинопатией (ДР) [1].

По причине растущей потребности в квалифицированной медицинской помощи пациентам в отдаленных регионах страны и в условиях ограничений, вызванных пандемией, возрастает нагрузка на использование информационных технологий в медицине.

Телемедицинские консультации по профилю «Офтальмология» набирают популярность:

- определение (подтверждение) тактики лечения;
- согласование условий и срока госпитализации в федеральную медицинскую организацию;
- определение (подтверждение) диагноза;
- необходимость выполнения нового и/или редкого вида оперативного вмешательства, процедуры и т.д.;
- разбор клинических случаев;
- формирование экспертного мнения по результатам диагностических исследований;
- другое [2].

В России лидерами по оказанию услуг телемедицины являются крупные города – центры медицинской науки и образования. МНТК «Микрохирургия глаза» улучшает качество услуг, используя в своей практике телемедицинские технологии [3].

В офтальмологии автоматизированная диагностика заболеваний по изображениям глаз пациентов осуществляется посредством методов машинного глубокого обучения [4]. Сверточные нейронные сети распознают снимки глаза [5].

Таким образом, положительная динамика по выявлению сахарного диабета у населения приводит к связанному с ним увеличению выявленного количества пациентов с ухудшенным зрением. В условиях пандемии возрастает нагрузка на медперсонал, что способствует росту использования технологий телемедицины.

В статье представлены результаты исследований методов глубокого машинного обучения в решении задач компьютерного зрения в области офтальмологии для диагностирования заболевания глаза. Изучены нейросетевые методы анализа изображений для диагностирования диабетической ретинопатии.

Целью исследования является анализ статей, посвященных задаче диагностирования по изображениям глаза, наличия поражения органа зрения с помощью нейронных сетей. Для достижения цели необходимо решить следующие задачи:

- 1) определить популярные методы анализа изображений глаза в диагностировании диабетической ретинопатии;
- 2) отметить достоинства и недостатки отобранных методов;
- 3) рассмотреть предлагаемые возможности для улучшения используемых подходов распознавания изображений органов зрения при определении диабетической ретинопатии.

Сбор и подготовка наборов данных

Исследователи в работе [27] отмечают, что сравнивать разные методы сложно по причине того, что многие методы не тестируются на общедоступных данных. Авторы работы делают вывод, что результаты показывают проблемы воспроизведения результатов методов глубокого обучения. Поэтому рекомендуют следующие улучшения в отчетности о методах глубокого обучения: использовать общедоступные данные или предоставлять подробное описание данных, публиковать исходный код или все подробности относительно предварительной обработки данных и все гиперпараметры.

Авторы работы [16] обозначают, что сильной стороной данного исследования является использование хорошо известных, крупномасштабных, общедоступных фотографий глазного дна, подготовленных для глубокого обучения, а также возможность воспроизведения результатов и сравнения с другими исследованиями.

Авторы статьи [22] делают вывод, что сбор данных из одного медицинского центра и из одной этнической группы делает набор данных относительно небольшим и менее гетерогенным.

Исследование [8] посвящено созданию двух систем глубокого обучения для прогнозирования развития диабетической ретинопатии и проверены на двух наборах данных: наборе внутренней проверки, содержащем изображения преимущественно латиноамериканских пациентов из США, и наборе внешней проверки из Таиланда.

Исследование [43] доказывает, что в настоящее время необходимость использования больших наборов данных для обучения является одним из са-

мых больших недостатков при обработке и классификации изображений с использованием архитектур нейронных сетей.

Авторы работы [49] делают вывод, что трудно различить изображения между 0 и 1 стадиями поражений. Поэтому, когда будут собираться новые данные, желательно собрать больше изображений, принадлежащих к 0 и 1 стадиям поражений. Наличие большего количества данных увеличит точность классификации.

В работе [38] исследователи делают вывод, что ограничением разработанного подхода, которое обычно встречается в моделях глубокого обучения, является полнота используемых наборов данных и время обучения, связанное с использованием очень большого количества изображений.

Предварительная обработка данных

Авторы статьи [33] делают вывод, что изображения в наборе данных были получены с использованием камер разных производителей и моделей. Кроме того, могут присутствовать шумы на изображениях, такие как размытый фокус, недодержка или передержка. Поэтому необходимо использовать методы обработки изображений, чтобы извлечь из этих изображений полезные признаки для дальнейшего анализа.

Исследование [31] посвящено решению нескольких проблем с набором данных, в том числе: чрезмерно зашумленные изображения, дубликаты изображений с неправильной маркировкой, неравномерное разрешение изображения и различные размеры выборки классов.

По результатам исследования [19] предложен метод нормализации яркости как один из этапов предварительной обработки для точной работы модели с изображениями глазного дна, полученными с разных камер при разных условиях освещения.

Авторы работы [20] делают вывод, что точность алгоритма зависит от качества полученных изображений сетчатки, и это является основным ограничивающим шагом для его глобального внедрения в немидриатический скрининг ДР сообщества с использованием портативных камер.

В работе [25] по результатам исследования представлен DL-алгоритм, способный выполнять первоначальный анализ изображения, чтобы определить, можно ли его оценить или нет, т.е. имеет ли изображение достаточно высокое качество или его необходимо повторить.

Авторы статьи [23] делают вывод, что оценка качества изображения с помощью искусственного интеллекта может уменьшить долю некачественных изображений. Кроме того, с улучшением качества изображения достоверно повысилась точность диагностики, особенно при легкой степени ДР.

Исследование [50] доказывает, что в будущем планируют внести изменения в некоторые методы предварительной обработки, а также обсудить, как эти изменения влияют на работу модели по классификации стадий ДР.

Задача распознавания изображений

По результатам исследования [37] авторы работы делают вывод, что применение сверточных нейронных сетей (CNN) в обнаружении ДР включает три основные сложные задачи: классификацию, сегментацию и обнаружение.

В статье [42] результаты экспериментов показывают, что сегментация и обнаружение поражения намного сложнее, чем классификация ДР, поэтому

необходимы дополнительные исследования алгоритмов глубокого обучения для скрининга диабетической ретинопатии.

Трансферное обучение

Авторы работы [39] использовали модель сверточной нейронной сети, обученной на наборе данных ImageNet, в которой затем заморозили первые несколько слоев модели. Но переобучили последние несколько слоев сети на общедоступном наборе обучающих данных.

В работе [7] по результатам исследования предлагается использовать методологию трансферного обучения, а именно модель сверточной нейронной сети на основе архитектуры DenseNet121.

Авторами статьи [15] предлагается подход глубокого обучения для ранней диагностики ретинопатии с использованием сверточной сети DenseNet-169, которая классифицирует изображения глазного дна в зависимости от степени тяжести: без ДР, легкой, умеренной, тяжелой и пролиферативной ДР.

Исследование [6] посвящено изучению метода на основе трансферного обучения. Авторы использовали предварительно обученную нейронную сеть DenseNet. Модель дала результаты, сопоставимые с предшествующими в литературе с учетом ограничений данных и оборудования, а также наличия искаженных классов.

Исследование [9] доказывает, что в будущем с использованием трансферного обучения моделями DL можно достичь высокой точности в обнаружении и оценке степени тяжести диабетической ретинопатии, что может помочь в выборе подходящей стратегии лечения ДР.

Сравнение методов

В работе [35] по результатам исследования используются предварительно обученные на ImageNet модели ResNet, DenseNet и DetNet. Во время эксперимента показано, что ResNet может превзойти две другие сети с точки зрения точности и эффективности. Авторы делают вывод, что в будущей работе планируется тщательно оценивать производительность каждой сети с различными значениями гиперпараметров. Настройка гиперпараметров может повлиять на точность каждой архитектуры.

По результатам исследования [41] предлагается использовать DenseNet-100 вместо ResNet-101 в качестве базовой сети традиционной архитектуры CenterNet.

В статье [11] использовали три типа архитектур сверточных нейронных сетей, например, Inception-v3, ResNet101 и DenseNet121 с одним и тем же обучающим набором данных для обучения моделей. Исследование доказывает, что с учетом сложности модели Inception-v3 может быть оптимальной моделью из трех. Поскольку модели ResNet101 и DenseNet121 сложнее, чем Inception-v3, теоретически они должны превосходить Inception-v3. Однако при использовании ResNet101 и DenseNet121 значительного улучшения не наблюдалось, сложности модели Inception-v3 было достаточно для обнаружения ДР на изображениях глазного дна.

Авторами работы [17] по результатам исследования продемонстрирована лучшая производительность сети VGG-16 при извлечении признаков из

CECED изображения глазного дна по сравнению с изображениями глазного дна CLANE. Inception V3 показал значительное улучшение производительности при извлечении признаков из изображений глазного дна CLANE по сравнению с CECED.

Авторы статьи [46] по результатам исследования вместо использования изображений глазного дна одного глаза в качестве входных данных построили новую модель CNN на основе обученной с помощью трансферного обучения Inception V3, которая способна принимать изображения глазного дна обоих глаз в качестве входных данных и выводить результат классификации каждого глаза одновременно. Предложенная модель бинокля обеспечивает более высокую производительность, чем модель монокуляра Inception V3. Однако у бинокулярных моделей возникнут трудности в обучении или тестировании с другим набором данных, в котором парные изображения глазного дна недоступны.

По результатам исследования [29] предлагается подход, который превосходит шесть существующих современных архитектур, а именно ResNet-50, VGG-19, Inception-v3, MobileNet, Xception и VGG16.

Исследователями [28] предложен подход, который приводит к более высокой диагностической точности, чувствительности и специфичности по сравнению с другими, основанными на CNN, и методами на основе SVM, опубликованными в литературе. Исследователи делают выводы:

- методы глубокого обучения, включая CNN, подвержены переобучению. Поэтому чтобы свести к минимуму переобучение и обеспечить беспристрастную оценку при использовании доступного ограниченного набора данных, предложены способы увеличения данных для каждого класса, а также использование перекрестной проверки;

- кроме того, они продолжают развёртывание капсульных сетей, недавно представленных Джеффри Хинтоном, чтобы классифицировать изображения глазного дна.

Ансамбли моделей

Исследование [12] посвящено гибриднему подходу к классификации диабетической ретинопатии с использованием предварительно обученных глубоких сверточных нейронных сетей, таких как InceptionV3 и VGG19. Гибридный подход состоит из таких этапов, как выбор данных, масштабирование изображения, извлечение признаков, объединение признаков и выбор признаков.

Исследование [30] доказывает, что предложенный метод с использованием гибридного подхода превосходит другие существующие подходы.

Авторы работы [18] по результатам исследования делают вывод, что гибридная модель по сравнению с единой базовой моделью может улучшить характеристики классификации во всех аспектах: точности, чувствительности, специфичности, прецизионности и F1-оценки.

Авторы статьи [45] по результатам исследования делают вывод, что в будущем можно улучшить производительность модели путем добавления дополнительных слоев.

Исследование [14] доказывает, что разнообразие базовых классификаторов, используемых для структуры ансамбля, является ключевым фактором для высокой точности классификации модели ансамбля.

В работе [48] по результатам исследования для VeriSee использовались как модифицированные архитектуры ResNet, так и Inception-v4 для разных характеристик сети. Авторы работы делают вывод, что предложенные алгоритмы в этом исследовании не были обучены дифференцировать диабетическую ретинопатию от других заболеваний сетчатки, таких как возрастная дегенерация желтого пятна, окклюзия вен сетчатки и т.д.

В статье [40] по результатам исследования представлена объединенная модель для лечения трех заболеваний глаз, т.е. диабетической ретинопатии, диабетического макулярного отека и глаукомы. Авторы статьи делают вывод, что в будущем исследовательская работа будет расширена за счет изучения других заболеваний сетчатки, таких как катаракта, возрастная дегенерация отека желтого пятна и т.д.

Исследование [47] доказывает, что в будущих работах больше внимания будет уделяться нейронным сетям, спроектированным на основе объединения функций (ансамблевого обучения).

Разработка системы

Авторы работы [36] по результатам исследования установили, что последние технологические достижения сделали доступными на рынке системы обработки изображений сетчатки на базе смартфонов для выполнения малогабаритного, маломощного и доступного по цене скрининга ДР в разнообразных средах.

В настоящее время существует несколько проблем для создания системы распознавания изображений на смартфонах: из-за ограничений вычислительной мощности, емкости батареи и свойства камеры в смартфонах.

Например, изображения, снятые системами на базе смартфонов, имеют более низкое качество и более узкое поле зрения по сравнению с традиционной камерой глазного дна из-за меньшего количества контролируемых параметров, большей чувствительности к изменению освещения и недорогим линзам, использованным в конструкции. Поэтому необходимо учитывать все сложные вопросы при разработке алгоритмов для систем обработки изображений на базе смартфонов.

В работе [34] учтена не только цель повышения точности классификации, но также приняты во внимание два важных вопроса для реального развертывания решения: вычислительная сложность и сложность реализации.

По результатам исследования сделана ставка на эффективность и простоту сети. Такой результат важен для развертывания решения на мобильных устройствах и устройствах с низким энергопотреблением. Авторы делают вывод, что в дальнейшей работе запланировано улучшение понимания, как сеть достигает своего решения. В частности, запланировано сделать процедуру принятия решений более интерпретируемой, чтобы обеспечить подотчетную процедуру проверки врачам.

В будущей работе запланировано исследование усиления моделей, которые позволят эффективно выбирать между точностью и потреблением объема памяти, чтобы обойти облачные сервисы и встраивать в портативные ретинальные камеры.

Авторы статьи [44] делают вывод: при скрининге населения с серьезными заболеваниями достижение высокой чувствительности и высокой спе-

цифичности имеет решающее значение для получения минимальных ложноположительных и ложноотрицательных результатов.

В исследовании [21] предложено решение, которое, с одной стороны, классифицирует изображения сетчатки на разные уровни тяжести с хорошей производительностью. С другой стороны, классификатор может объяснять результаты классификации.

Исследование [32] доказывает, что будущая цель этого исследования – разработка недорогого оборудования, способного классифицировать изображения сетчатки в реальном времени на месте. Авторы делают вывод, что это может быть достигнуто дальнейшей оптимизацией представленной модели или рассмотрением альтернативных моделей, таких как рекуррентная нейронная сеть.

В работе [13] цель заключалась в уменьшении сложности модели при одновременном повышении ее производительности. С этой целью разработана эффективная профессиональная методика выбора тренировочных патчей. Авторы делают вывод о необходимости дальнейших исследований, создании отдельных моделей для каждого типа поражения, такой как МА, кровоизлияния и даже яркие поражения, такие как экссудаты.

По результатам исследования [24] выявлено 11 случаев оцененных вручную референтной ДР, ошибочно классифицированных как не имеющие ДР автоматизированной системой. Авторы делают вывод, что, несмотря на ограниченную специфичность, автоанализ изображения сетчатки потенциально может быть ценным в различных сценариях скрининга ДР с относительно высокой чувствительностью.

Общие замечания

Британская диабетическая ассоциация предложила, чтобы любая программа скрининга диабетической ретинопатии должна иметь чувствительность не менее 80 % и специфичность 95 %.

Несмотря на то что значительные успехи были достигнуты в анализе изображений сетчатки глаза, еще есть место для поиска лучшего алгоритма, который превосходит все с точки зрения точности. Причем предлагаемый способ должен нести минимум ложноотрицательных результатов и помогать офтальмологам сосредоточиться на поражениях на изображениях глазного дна. Основной проблемой в САПР обнаружения микроаневризм (МА) является неспособность алгоритма обнаружить МА очень близко к кровеносным сосудам или очень тонкий МА.

Ученые делают вывод, что в литературе есть несколько алгоритмов, которые могут помочь офтальмологу в простом компьютерном скрининге ДР. Метод считается лучшим, если он быстрый, рентабельный и точный. Все эти ограничения – потребность времени. Это действительно сложно для исследователей – определить лучшие алгоритмы и получить эффективную пропускную способность. У молодых исследователей есть огромные новые области, такие как глубокое обучение, но с минимальным временем обучения, изучение словаря для конкретных поражений, поиск лучших характеристик и надежных классификаторов для достижения самых высоких показателей точности [10].

Исследование [26] доказывает, что применение автоматизированного инструмента оценки ДР на базе DL по цветным изображениям глазного дна может предоставить альтернативное решение для уменьшения количества ошибочных диагнозов и улучшения рабочего процесса. Автоматизированные инструменты могут улучшить качество скрининга ДР, доступность медицинских услуг, ухода, а также снизить стоимость обследования. Более раннее обнаружение и своевременное лечение могут предотвратить начало болезни или помогут остановить прогрессирование на более раннем этапе.

Заключение

Таким образом, исходя из проведенного обзора литературы, методы машинного обучения широко распространены в решении задач компьютерного зрения для офтальмологии. Вместе с тем глубокое обучение характеризуется высокой точностью, чувствительностью и специфичностью по результатам распознавания заболеваний на изображениях глаза. Кроме того, в последние годы наблюдается рост заболеваемости сахарным диабетом и ухудшения зрения от диабетической ретинопатии. Это обуславливает необходимость увеличения количества обезличенных размеченных профилем специалистом медицинского учреждения наборов данных изображений глаза для своевременного лечения и профилактики диабетической ретинопатии. В связи с этим требуется рассмотреть возможности улучшения методов предварительной обработки изображений.

Однако существующие на сегодня нейросетевые методы определения диабетической ретинопатии являются недостаточно интерпретируемыми, вызывают ложноположительные и ложноотрицательные результаты диагностики, обладают недостаточной способностью к сегментации поражения глаза на изображениях и к классификации для установления диагноза между отсутствием заболевания и наличием начальной стадии легкой степени тяжести поражения глаза, недоступны для широкого внедрения на мобильных устройствах вследствие высокой вычислительной мощности. Поэтому рекомендовано исследовать объединение различных моделей в ансамбли, которое за счет преимуществ каждой отдельной нейронной сети улучшит общий результат.

В настоящее время разработаны методы, успешно применяемые при схожих задачах распознавания изображений: капсульные и рекуррентные нейронные сети. В литературе есть единичные описания исследований применения капсульных и рекуррентных нейронных сетей при определении диабетической ретинопатии по изображениям глаза. Ввиду этого возможно использование предложенных алгоритмов в диагностировании заболеваний глаза.

Список литературы

1. Дедов И. И., Шестакова М. В., Викулова О. К. [и др.]. Атлас регистра сахарного диабета Российской Федерации. Статус 2018 г. // Сахарный диабет. 2019. Т. 22, № 2S. С. 4–61. doi:10.14341/DM12208
2. Чухраев А. М., Ходжаев Н. С., Кечин Е. В. Анализ структуры телемедицинских консультаций по профилю «Офтальмология» в Российской Федерации // Здоровоохранение Российской Федерации. 2020. Т. 64, № 1. С. 22–28. doi:10.18821/0044-197X-2019-64-1-22-28

3. Черных В. В., Ходжаев Н. С., Шахов В. Г. Методология развития телемедицинских и информационных систем ФГАУ «МНТК «Микрохирургия глаза» им. акад. С.Н. Федорова» Минздрава России на примере Новосибирского филиала // Офтальмохирургия. 2018. № 1. С. 84–90. doi:10.25276/0235-4160-2018-1-84-90
4. Добров Э. Р. Применение больших данных в телеофтальмологии // Инженерный вестник Дона. 2021. № 7. С. 138–157.
5. 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. Т. 2, № 2. С. 64–72. doi:10.47093/2713-069X.2021.2.2.64-72
6. Samanta A., Saha A., Satapathy S. C. [et al.]. Automated detection of diabetic retinopathy using convolutional neural networks on a small dataset // Pattern Recognition Letters. 2020. Vol. 135. P. 293–298. doi:10.1016/j.patrec.2020.04.026
7. Ayala A., Figueroa T. O., Fernandes B., Cruz F. Diabetic Retinopathy Improved Detection Using Deep Learning // Applied Sciences. 2021. Vol. 11, № 24. P. 1–11. doi:10.3390/app112411970
8. Bora A., Balasubramanian S., Babenko B. [et al.]. Predicting the risk of developing diabetic retinopathy using deep learning // The Lancet Digital Health. 2021. Vol. 3, № 1. P. 10–19. doi:10.1016/S2589-7500(20)30250-8
9. Sugeno A., Ishikawa Y., Ohshima T., Muramatsu R. Simple methods for the lesion detection and severity grading of diabetic retinopathy by image processing and transfer learning // Computers in Biology and Medicine. 2021. Vol. 137, № 14. P. 1–9. doi:10.1016/j.compbiomed.2021.104795
10. Biyani R. S., Patre B. M. Algorithms for red lesion detection in Diabetic Retinopathy: A review // Biomedicine & Pharmacotherapy. 2018. Vol. 107, № 4. P. 681–688. doi:10.1016/j.biopha.2018.07.175
11. Tsai C.-Y., Chen C.-T., Chen G.-A. [et al.]. Necessity of Local Modification for Deep Learning Algorithms to Predict Diabetic Retinopathy // International Journal of Environmental Research and Public Health. 2022. Vol. 19, № 3. P. 1–12. doi:10.3390/ijerph19031204
12. Zia F., Irum I., Qadri N. N. [et al.]. A Multilevel Deep Feature Selection Framework for Diabetic Retinopathy Image Classification // Computers, Materials & Continua. 2022. Vol. 70, № 2. P. 2261–2276. doi:10.32604/cmc.2022.017820
13. Zago G. T., Andreao R. V., Dorizzi B. [et al.]. Diabetic retinopathy detection using red lesion localization and convolutional neural networks // Computers in Biology and Medicine. 2020. Vol. 116. P. 1–12. doi:10.1016/j.compbiomed.2019.103537
14. Jinfeng G., Qummar S., Junming Z. [et al.]. Ensemble Framework of Deep CNNs for Diabetic Retinopathy Detection // Hindawi Computational Intelligence and Neuroscience. 2020. Vol. 2020. P. 1–11. doi:10.1155/2020/8864698
15. Mushtaq G., Siddiqui F. Detection of diabetic retinopathy using deep learning methodology // IOP Conference Series: Materials Science and Engineering. 2021. Vol. 1070, № 012049. P. 1–13. doi:10.1088/1757-899X/1070/1/012049
16. Lin G.-M., Chen M.-J., Yeh C.-H. [et al.]. Transforming Retinal Photographs to Entropy Images in Deep Learning to Improve Automated Detection for Diabetic Retinopathy // Hindawi Journal of Ophthalmology. 2018. Vol. 2018. P. 1–6. doi:10.1155/2018/2159702
17. Nneji G. U., Cai J., Deng J. [et al.]. Identification of Diabetic Retinopathy Using Weighted Fusion Deep Learning Based on Dual-Channel Fundus Scans // Diagnostics. 2022. Vol. 12, № 2. P. 1–19. doi:10.3390/diagnostics12020540
18. Liu H., Yue K., Cheng S. [et al.]. Hybrid Model Structure for Diabetic Retinopathy Classification // Hindawi Journal of Healthcare Engineering. 2020. Vol. 2020. P. 1–9. doi:10.1155/2020/8840174

19. Kaushik H., Singh D., Kaur M. [et al.]. Diabetic Retinopathy Diagnosis From Fundus Images Using Stacked Generalization of Deep Models // *IEEE Access*. 2021. Vol. 9. P. 108276–108292. doi:10.1109/ACCESS.2021.3101142
20. Rio J. M. N. do, Nderitu P., Bergeles C. [et al.]. Evaluating a Deep Learning Diabetic Retinopathy Grading System Developed on Mydriatic Retinal Images When Applied to Non-Mydriatic Community Screening // *Journal of Clinical Medicine*. 2022. Vol. 11, № 3. P. 1–11. doi:10.3390/jcm11030614
21. Torre J. de la, Valls A., Puig D. A deep learning interpretable classifier for diabetic retinopathy disease grading // *Neurocomputing*. 2020. Vol. 396. P. 465–476. doi:10.1016/j.neucom.2018.07.102
22. Lo J.-E., Kang E. Y.-C., Chen Y.-N. [et al.]. Data Homogeneity Effect in Deep Learning-Based Prediction of Type 1 Diabetic Retinopathy // *Hindawi Journal of Diabetes Research*. 2021. Vol. 2021. P. 1–9. doi:10.1155/2021/2751695
23. Dai L., Wu L., Li H. [et al.]. A deep learning system for detecting diabetic retinopathy across the disease spectrum // *Nature Communications*. 2021. Vol. 12, № 3242. P. 1–11. doi:10.1038/s41467-021-23458-5
24. Nørgaard M. F., Grauslund J. Automated Screening for Diabetic Retinopathy – A Systematic Review // *Ophthalmic Research*. 2018. Vol. 60, № 1. P. 1–9. doi:10.1159/000486284
25. Baget-Bernaldiz M., Pedro R.-A., Santos-Blanco E. [et al.]. Testing a Deep Learning Algorithm for Detection of Diabetic Retinopathy in a Spanish Diabetic Population and with MESSIDOR Database // *Diagnostics*. 2021. Vol. 11, № 8. P. 1–11. doi:10.3390/diagnostics11081385
26. Islam M. M., Yang H.-C., Poly T. N. [et al.]. Deep learning algorithms for detection of diabetic retinopathy in retinal fundus photographs: A systematic review and meta-analysis // *Computer Methods and Programs in Biomedicine*. 2020. Vol. 191, № 10. P. 1–16. doi:10.1016/j.cmpb.2020.105320
27. Voets M., Möllersen K., Bongo L. A. Reproduction study using public data of: Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs // *PLOS ONE*. 2019. Vol. 14, № 6. P. 1–11. doi:10.1371/journal.pone.0217541
28. Shaban M., Ogur Z., Mahmoud A. [et al.]. A convolutional neural network for the screening and staging of diabetic retinopathy // *PLOS ONE*. 2020. Vol. 15, № 6. P. 1–13. doi:10.1371/journal.pone.0233514
29. Yaqoob M. K., Ali S. F., Bilal M. [et al.]. ResNet Based Deep Features and Random Forest Classifier for Diabetic Retinopathy Detection // *Sensors*. 2021. Vol. 21, № 11. P. 1–14. doi:10.3390/s21113883
30. Mateen M., Malik T. S., Hayat S. [et al.]. Deep Learning Approach for Automatic Microaneurysms Detection // *Sensors*. 2022. Vol. 22, № 2. P. 1–14. doi:10.3390/s22020542
31. Sikder N., Masud M., Bairagi A. K. [et al.]. Severity Classification of Diabetic Retinopathy Using an Ensemble Learning Algorithm through Analyzing Retinal Images // *Symmetry*. 2021. Vol. 13, № 4. P. 1–26. doi:10.3390/sym13040670
32. Vora P., Shrestha S. Detecting Diabetic Retinopathy Using Embedded Computer Vision // *Applied Sciences*. 2020. Vol. 10, № 20. P. 1–10. doi:10.3390/app10207274
33. Chen P.-N., Lee C.-C., Liang C.-M. [et al.]. General deep learning model for detecting diabetic retinopathy // *BMC Bioinformatics*. 2021. Vol. 22, № 84. P. 1–14. doi:10.1186/s12859-021-04005-x
34. Pires R., Avila S., Wainer J. [et al.]. A data-driven approach to referable diabetic retinopathy detection // *Artificial Intelligence In Medicine*. 2019. Vol. 96. P. 93–106. doi:10.1016/j.artmed.2019.03.009

35. Adriman R., Muchtar K., Maulina N. Performance Evaluation of Binary Classification of Diabetic Retinopathy through Deep Learning Techniques using Texture Feature // *Procedia Computer Science*. 2021. Vol. 179. P. 88–94. doi:10.1016/j.procs.2020.12.012
36. Hacısoftaoglu R. E., Karakaya M., Sallam A. B. Deep learning frameworks for diabetic retinopathy detection with smartphone-based retinal imaging systems // *Pattern Recognition Letters*. 2020. Vol. 135, № 4. P. 409–417. doi:10.1016/j.patrec.2020.04.009
37. Wan S., Liang Y., Zhang Y. Deep convolutional neural networks for diabetic retinopathy detection by image classification // *Computers and Electrical Engineering*. 2018. Vol. 72. P. 274–282. doi:10.1016/j.compeleceng.2018.07.042
38. Majumder S., Kehtarnavaz N. Multitasking Deep Learning Model for Detection of Five Stages of Diabetic Retinopathy // *IEEE Access*. 2021. Vol. 9. P. 123220–123230. doi:10.1109/ACCESS.2021.3109240
39. Goel S., Gupta S., Panwar A. [et al.]. Deep Learning Approach for Stages of Severity Classification in Diabetic Retinopathy Using Color Fundus Retinal Images // *Hindawi Mathematical Problems in Engineering*. 2021. Vol. 2021. P. 1–8. doi:10.1155/2021/7627566
40. Nazir T., Irtaza A., Javed A. [et al.]. Retinal Image Analysis for Diabetes-Based Eye Disease Detection Using Deep Learning // *Applied Sciences*. 2020. Vol. 10, № 18. P. 1–21. doi:10.3390/app10186185
41. Nazir T., Nawaz M., Rashid J. [et al.]. Detection of Diabetic Eye Disease from Retinal Images Using a Deep Learning Based CenterNet Model // *Sensors*. 2021. Vol. 21, № 16. P. 1–18. doi:10.3390/s21165283
42. Li T., Gao Y., Wang K. [et al.]. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening // *Information Sciences*. 2019. Vol. 501, № 13. P. 511–522. doi:10.1016/j.ins.2019.06.011
43. Vives-Boix V., Ruiz-Fernández D. Diabetic retinopathy detection through convolutional neural networks with synaptic metaplasticity // *Computer Methods and Programs in Biomedicine*. 2021. Vol. 206, № 6. P. 1–8. doi:10.1016/j.cmpb.2021.106094
44. Zhang W., Zhong J., Yang S. [et al.]. Automated identification and grading system of diabetic retinopathy using deep neural networks // *Knowledge-Based Systems*. 2019. Vol. 175. P. 12–25. doi:10.1016/j.knosys.2019.03.016
45. Alyoubi W. L., Abulkhair M. F., Shalash W. M. Diabetic Retinopathy Fundus Image Classification and Lesions Localization System Using Deep Learning // *Sensors*. 2021. Vol. 21, № 11. P. 1–22. doi:10.3390/s21113704
46. Zeng X., Chen H., Luo Y., Ye W. Automated Diabetic Retinopathy Detection Based on Binocular Siamese-Like Convolutional Neural Network // *IEEE Access*. 2019. Vol. 7. P. 30744–30753. doi:10.1109/ACCESS.2019.2903171
47. Liu Y.-P., Li Z., Xu C. [et al.]. Referable diabetic retinopathy identification from eye fundus images with weighted path for convolutional neural network // *Artificial Intelligence In Medicine*. 2019. Vol. 99, № 3. P. 1–7. doi:10.1016/j.artmed.2019.07.002
48. Hsieh Y.-T., Chuang L.-M., Jiang Y.-D. [et al.]. Application of deep learning image assessment software VeriSee for diabetic retinopathy screening // *Journal of the Formosan Medical Association*. 2021. Vol. 120, № 1. P. 165–171. doi:10.1016/j.jfma.2020.03.024
49. Li Y.-H., Yeh N.-N., Chen S.-J., Chung Y.-C. Computer-Assisted Diagnosis for Diabetic Retinopathy Based on Fundus Images Using Deep Convolutional Neural Network // *Hindawi Mobile Information Systems*. 2019. Vol. 2019. P. 1–14. doi:10.1155/2019/6142839
50. Khan Z., Khan F. G., Khan A. [et al.]. Diabetic Retinopathy Detection Using VGG-NIN a Deep Learning Architecture // *IEEE Access*. 2021. Vol. 9. P. 61408–61416. doi:10.1109/ACCESS.2021.3074422

References

1. Dedov I.I., Shestakova M.V., Vikulova O.K. [et al.]. Atlas of the register of diabetes mellitus of the Russian Federation. Status 2018. *Sakharnyy diabet = Diabetes mellitus*. 2019;22(2S):4–61. (In Russ.). doi:10.14341/DM12208
2. Chukhraev A.M., Khodzhaev N.S., Kechin E.V. Analysis of the structure of telemedicine consultations on the profile "Ophthalmology" in the Russian Federation. *Zdravookhranenie Rossiyskoy Federatsii = Health of the Russian Federation*. 2020;64(1):22–28. (In Russ.). doi:10.18821/0044-197X-2019-64-1-22-28
3. Chernykh V.V., Khodzhaev N.S., Shakhov V.G. Methodology of development of telemedicine and information systems of FSAU "MNTC "Eye Microsurgery" named after Academician S.N. Fedorov" of the Ministry of Health of Russia on the example of the Novosibirsk branch. *Oftal'mokhirurgiya = Ophthalmosurgery*. 2018;(1):84–90. (In Russ.). doi:10.25276/0235-4160-2018-1-84-90
4. Dobrov E.R. Application of big data in teleophthalmology. *Inzhenernyy vestnik Dona = Engineering Bulletin of the Don*. 2021;(7):138–157. (In Russ.)
5. Neroev V.V., Bragin A.A., Zaytseva O.V. Development of a prototype service for the diagnosis of diabetic retinopathy from fundus images using artificial intelligence methods. *Natsional'noe zdravookhranenie = National Healthcare*. 2021;2(2):64–72. (In Russ.). doi:10.47093/2713-069X.2021.2.2.64-72
6. Samanta A., Saha A., Satapathy S.C. [et al.]. Automated detection of diabetic retinopathy using convolutional neural networks on a small dataset. *Pattern Recognition Letters*. 2020;135:293–298. doi:10.1016/j.patrec.2020.04.026
7. Ayala A., Figueroa T.O., Fernandes B., Cruz F. Diabetic Retinopathy Improved Detection Using Deep Learning. *Applied Sciences*. 2021;11(24):1–11. doi:10.3390/app112411970
8. Bora A., Balasubramanian S., Babenko B. [et al.]. Predicting the risk of developing diabetic retinopathy using deep learning. *The Lancet Digital Health*. 2021;3(1):10–19. doi:10.1016/S2589-7500(20)30250-8
9. Sugeno A., Ishikawa Y., Ohshima T., Muramatsu R. Simple methods for the lesion detection and severity grading of diabetic retinopathy by image processing and transfer learning. *Computers in Biology and Medicine*. 2021;137(14):1–9. doi:10.1016/j.compbiomed.2021.104795
10. Biyani R.S., Patre B.M. Algorithms for red lesion detection in Diabetic Retinopathy: A review. *Biomedicine & Pharmacotherapy*. 2018;107(4):681–688. doi:10.1016/j.biopha.2018.07.175
11. Tsai C.-Y., Chen C.-T., Chen G.-A. [et al.]. Necessity of Local Modification for Deep Learning Algorithms to Predict Diabetic Retinopathy. *International Journal of Environmental Research and Public Health*. 2022;19(3):1–12. doi:10.3390/ijerph19031204
12. Zia F., Irum I., Qadri N.N. [et al.]. A Multilevel Deep Feature Selection Framework for Diabetic Retinopathy Image Classification. *Computers, Materials & Continua*. 2022;70(2):2261–2276. doi:10.32604/cmc.2022.017820
13. Zago G.T., Andreao R.V., Dorizzi B. [et al.]. Diabetic retinopathy detection using red lesion localization and convolutional neural networks. *Computers in Biology and Medicine*. 2020;116:1–12. doi:10.1016/j.compbiomed.2019.103537
14. Jinfeng G., Qummar S., Junming Z. [et al.]. Ensemble Framework of Deep CNNs for Diabetic Retinopathy Detection. *Hindawi Computational Intelligence and Neuroscience*. 2020;2020:1–11. doi:10.1155/2020/8864698
15. Mushtaq G., Siddiqui F. Detection of diabetic retinopathy using deep learning methodology. *IOP Conference Series: Materials Science and Engineering*. 2021;1070(012049):1–13. doi:10.1088/1757-899X/1070/1/012049
16. Lin G.-M., Chen M.-J., Yeh C.-H. [et al.]. Transforming Retinal Photographs to Entropy Images in Deep Learning to Improve Automated Detection for Diabetic Reti-

- nopathy. *Hindawi Journal of Ophthalmology*. 2018;2018:1–6. doi:10.1155/2018/2159702
17. Nneji G.U., Cai J., Deng J. [et al.]. Identification of Diabetic Retinopathy Using Weighted Fusion Deep Learning Based on Dual-Channel Fundus Scans. *Diagnostics*. 2022;12(2):1–19. doi:10.3390/diagnostics12020540
18. Liu H., Yue K., Cheng S. [et al.]. Hybrid Model Structure for Diabetic Retinopathy Classification. *Hindawi Journal of Healthcare Engineering*. 2020;2020:1–9. doi:10.1155/2020/8840174
19. Kaushik H., Singh D., Kaur M. [et al.]. Diabetic Retinopathy Diagnosis From Fundus Images Using Stacked Generalization of Deep Models. *IEEE Access*. 2021;9:108276–108292. doi:10.1109/ACCESS.2021.3101142
20. Rio J.M.N. do, Nderitu P., Bergeles C. [et al.]. Evaluating a Deep Learning Diabetic Retinopathy Grading System Developed on Mydriatic Retinal Images When Applied to Non-Mydriatic Community Screening. *Journal of Clinical Medicine*. 2022;11(3):1–11. doi:10.3390/jcm11030614
21. Torre J. de la, Valls A., Puig D. A deep learning interpretable classifier for diabetic retinopathy disease grading. *Neurocomputing*. 2020;396:465–476. doi:10.1016/j.neucom.2018.07.102
22. Lo J.-E., Kang E. Y.-C., Chen Y.-N. [et al.]. Data Homogeneity Effect in Deep Learning-Based Prediction of Type 1 Diabetic Retinopathy. *Hindawi Journal of Diabetes Research*. 2021;2021:1–9. doi:10.1155/2021/2751695
23. Dai L., Wu L., Li H. [et al.]. A deep learning system for detecting diabetic retinopathy across the disease spectrum. *Nature Communications*. 2021;12(3242):1–11. doi:10.1038/s41467-021-23458-5
24. Nørgaard M.F., Grauslund J. Automated Screening for Diabetic Retinopathy – A Systematic Review. *Ophthalmic Research*. 2018;60(1):1–9. doi:10.1159/000486284
25. Baget-Bernaldiz M., Pedro R.-A., Santos-Blanco E. [et al.]. Testing a Deep Learning Algorithm for Detection of Diabetic Retinopathy in a Spanish Diabetic Population and with MESSIDOR Database. *Diagnostics*. 2021;11(8):1–11. doi:10.3390/diagnostics11081385
26. Islam M.M., Yang H.-C., Poly T. N. [et al.]. Deep learning algorithms for detection of diabetic retinopathy in retinal fundus photographs: A systematic review and meta-analysis. *Computer Methods and Programs in Biomedicine*. 2020;191(10):1–16. doi:10.1016/j.cmpb.2020.105320
27. Voets M., Möllersen K., Bongo L.A. Reproduction study using public data of: Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *PLOS ONE*. 2019;14(6):1–11. doi:10.1371/journal.pone.0217541
28. Shaban M., Ogur Z., Mahmoud A. [et al.]. A convolutional neural network for the screening and staging of diabetic retinopathy. *PLOS ONE*. 2020;15(6):1–13. doi:10.1371/journal.pone.0233514
29. Yaqoob M.K., Ali S.F., Bilal M. [et al.]. ResNet Based Deep Features and Random Forest Classifier for Diabetic Retinopathy Detection. *Sensors*. 2021;21(11):1–14. doi:10.3390/s21113883
30. Mateen M., Malik T. S., Hayat S. [et al.]. Deep Learning Approach for Automatic Microaneurysms Detection. *Sensors*. 2022;22(2):1–14. doi:10.3390/s22020542
31. Sikder N., Masud M., Bairagi A.K. [et al.]. Severity Classification of Diabetic Retinopathy Using an Ensemble Learning Algorithm through Analyzing Retinal Images. *Symmetry*. 2021;13(4):1–26. doi:10.3390/sym13040670
32. Vora P., Shrestha S. Detecting Diabetic Retinopathy Using Embedded Computer Vision. *Applied Sciences*. 2020;10(20):1–10. doi:10.3390/app10207274
33. Chen P.-N., Lee C.-C., Liang C.-M. [et al.]. General deep learning model for detecting diabetic retinopathy. *BMC Bioinformatics*. 2021;22(84):1–14. doi:10.1186/s12859-021-04005-x

34. Pires R., Avila S., Wainer J. [et al.]. A data-driven approach to referable diabetic retinopathy detection. *Artificial Intelligence In Medicine*. 2019;96:93–106. doi:10.1016/j.artmed.2019.03.009
35. Adriman R., Muchtar K., Maulina N. Performance Evaluation of Binary Classification of Diabetic Retinopathy through Deep Learning Techniques using Texture Feature. *Procedia Computer Science*. 2021;179:88–94. doi:10.1016/j.procs.2020.12.012
36. Hacisoftoglu R.E., Karakaya M., Sallam A.B. Deep learning frameworks for diabetic retinopathy detection with smartphone-based retinal imaging systems. *Pattern Recognition Letters*. 2020;135(4):409–417. doi:10.1016/j.patrec.2020.04.009
37. Wan S., Liang Y., Zhang Y. Deep convolutional neural networks for diabetic retinopathy detection by image classification. *Computers and Electrical Engineering*. 2018;72:274–282. doi:10.1016/j.compeleceng.2018.07.042
38. Majumder S., Kehtarnavaz N. Multitasking Deep Learning Model for Detection of Five Stages of Diabetic Retinopathy. *IEEE Access*. 2021;9:123220–123230. doi:10.1109/ACCESS.2021.3109240
39. Goel S., Gupta S., Panwar A. [et al.]. Deep Learning Approach for Stages of Severity Classification in Diabetic Retinopathy Using Color Fundus Retinal Images. *Hindawi Mathematical Problems in Engineering*. 2021;2021:1–8. doi:10.1155/2021/7627566
40. Nazir T., Irtaza A., Javed A. [et al.]. Retinal Image Analysis for Diabetes-Based Eye Disease Detection Using Deep Learning. *Applied Sciences*. 2020;10(18):1–21. doi:10.3390/app10186185
41. Nazir T., Nawaz M., Rashid J. [et al.]. Detection of Diabetic Eye Disease from Retinal Images Using a Deep Learning Based CenterNet Model. *Sensors*. 2021;21(16):1–18. doi:10.3390/s21165283
42. Li T., Gao Y., Wang K. [et al.]. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening. *Information Sciences*. 2019;501(13):511–522. doi:10.1016/j.ins.2019.06.011
43. Vives-Boix V., Ruiz-Fernández D. Diabetic retinopathy detection through convolutional neural networks with synaptic metaplasticity. *Computer Methods and Programs in Biomedicine*. 2021;206(6):1–8. doi:10.1016/j.cmpb.2021.106094
44. Zhang W., Zhong J., Yang S. [et al.]. Automated identification and grading system of diabetic retinopathy using deep neural networks. *Knowledge-Based Systems*. 2019;175:12–25. doi:10.1016/j.knosys.2019.03.016
45. Alyoubi W.L., Abulkhair M.F., Shalash W.M. Diabetic Retinopathy Fundus Image Classification and Lesions Localization System Using Deep Learning. *Sensors*. 2021;21(11):1–22. doi:10.3390/s21113704
46. Zeng X., Chen H., Luo Y., Ye W. Automated Diabetic Retinopathy Detection Based on Binocular Siamese-Like Convolutional Neural Network. *IEEE Access*. 2019;7:30744–30753. doi:10.1109/ACCESS.2019.2903171
47. Liu Y.-P., Li Z., Xu C. [et al.]. Referable diabetic retinopathy identification from eye fundus images with weighted path for convolutional neural network. *Artificial Intelligence In Medicine*. 2019;99(3):1–7. doi:10.1016/j.artmed.2019.07.002
48. Hsieh Y.-T., Chuang L.-M., Jiang Y.-D. [et al.]. Application of deep learning image assessment software VeriSee for diabetic retinopathy screening. *Journal of the Formosan Medical Association*. 2021;120(1):165–171. doi:10.1016/j.jfma.2020.03.024
49. Li Y.-H., Yeh N.-N., Chen S.-J., Chung Y.-C. Computer-Assisted Diagnosis for Diabetic Retinopathy Based on Fundus Images Using Deep Convolutional Neural Network. *Hindawi Mobile Information Systems*. 2019;2019:1–14. doi:10.1155/2019/6142839
50. Khan Z., Khan F.G., Khan A. [et al.]. Diabetic Retinopathy Detection Using VGG-NIN a Deep Learning Architecture. *IEEE Access*. 2021;9:61408–61416. doi:10.1109/ACCESS.2021.3074422

Информация об авторах / Information about the authors

Эльдар Робертович Добров
аспирант,
Новосибирский государственный
университет экономики и управления
(Россия, г. Новосибирск,
ул. Каменская, 56)
E-mail: sib.2020@bk.ru

Eldar R. Dobrov
Postgraduate student,
Novosibirsk State University
of Economics and Management
(56 Kamenskaya street,
Novosibirsk, Russia)

**Авторы заявляют об отсутствии конфликта интересов /
The authors declare no conflicts of interests.**

Поступила в редакцию/Received 16.03.2022
Поступила после рецензирования/Revised 28.04.2022
Принята к публикации/Accepted 17.05.2022