ПАТОЛОГИЯ СЕТЧАТКИ, СОСУДИСТОЙ ОБОЛОЧКИ И ЗРИТЕЛЬНОГО НЕРВА PATHOLOGY OF RETINA, CHOROID AND OPTIC NERVE OLOGY

Научная статья УДК 617.735-07 doi: 10.25276/0235-4160-2022-4S-70-76

Применение сверточных нейронных сетей для определения эндотелиальной дистрофии Фукса

С.В. Шухаев¹, Е.А. Мордовцева¹, Е.А. Пустозеров^{2, 3}, Ш.Ш. Кудлахмедов⁴

¹НМИЦ «МНТК «Микрохирургия глаза» им. акад. С.Н. Федорова» Минздрава России, Санкт-

Петербургский филиал, Санкт-Петербург

²СПбГЭТУ «ЛЭТИ» им. В.И. Ульянова, Санкт-Петербург

³НМИЦ им. В.А. Алмазова Минздрава России, Санкт-Петербург

⁴СЗГМУ им. И.И. Мечникова Минздрава России, Санкт-Петербург

ΡΕΦΕΡΑΤ

Цель. Оценить применение сверточных нейронных сетей для автоматического определения дистрофии Фукса. Материал и методы. Была произведена выборка случайных (n=700) биомикроскопических снимков роговицы, полученных при помощи эндотелиального микроскопа (Tomey EM-3000), из базы данных Санкт-Петербургского филиала «МНТК «Микрохирургия глаза» им. акад. С.Н. Федорова». На первом этапе выполнялось разделение снимков на 2 группы. Первая группа включала в себя снимки с наличием дистрофии Фукса, вторая – норму или другую патологию. Снимки плотности эндотелиальных клеток были разделены на три категории: тренировочный, валидационный и тестовый наборы данных. В нашем исследовании были протестированы различные архитектуры сверточных нейронных сетей: ResNet18, ResNet50, VGG16, VGG19 и GooqleNet. Результаты. В результате апробации нейронной сети на тестовой выборке получены следующие значения F-метрики для различных архитектур нейронных сетей: ResNet18: 0,985; ResNet50: 1,000; VGG16: 0,940; VGG19: 0,990; GoogleNet: 0,987. Сеть ResNet50 показала лучший результат при использовании предобученной сети на данных ImageNet с замороженными слоями, оптимизатором Adam, кросс-энтропией в качестве функции потерь и шагом обучения 0,000005. Заключение. Применение сверточных нейронных сетей для автоматического определения дистрофии Фукса может быть успешно реализовано в составе системы поддержки принятия решения врача. ResNet50 показала лучшие результаты среди всех типов архитектур и на тестовой выборке не выдала ни одной ошибки, что говорит о высокой эффективности применения данной сети в алгоритме классификации снимков эндотелия роговицы.

Ключевые слова: искусственный интеллект, дистрофия роговицы Фукса, сверточные нейронные сети **—**

Для цитирования: Шухаев С.В., Мордовцева Е.А., Пустозеров Е.А., Кудлахмедов Ш.Ш. Применение сверточных нейронных сетей для определения эндотелиальной дистрофии Фукса. Офтальмохирургия. 2022;4S: 70–76. doi: 10.25276/0235-4160-2022-4S-70-76 **Автор, ответственный за переписку:** Сергей Викторович Шухаев, shukhaevsv@gmail.com

ABSTRACT

Original article

Application of convolutional neural networks to define Fuchs endothelial dystrophy

S.V. Shukhaev¹, E.A. Mordovtseva¹, E.A. Pustozerov^{2, 3}, S.S. Kudlakhmedov⁴

¹Fyodorov Microsurgery Federal State Institution, the Saint-Petersburg branch, Saint-Petersburg, Russian Federation ²Saint Petersburg Electrotechnical University «LETI», Saint Petersburg, Russian Federation ³Almazov National Medical Research Centre, Saint Petersburg, Russian Federation ⁴North-Western State Medical University named after I.I. Mechnikov, Saint Petersburg, Russian Federation

Purpose. To evaluate the application of convolutional neural networks for the automatic detection of Fuchs' dystrophy. **Material and methods.** The study included 700 biomicroscopic images of the corneal endothelium (Tomey EM-3000) randomly selected from the database of the Saint-Petersburg brunch of the S. Fyodorov Eye Microsurgery Federal State Institution. At the first stage, the images were divided into 2 groups.

The first group included images with the presence of Fuchs' dystrophy, the second – another pathology or a healthy cornea. The corneal endothelial cell density images were divided into three categories: training, validation, and test datasets. In our study we tested various architectures of convolutional neural networks: ResNet18, ResNet50, VGG16, VGG19 and GoogleNet. **Results.** The approbation of the neural network on the

```
© Шухаев С.В., Мордовцева Е.А., Пустозеров Е.А., Кудлахмедов Ш.Ш., 2022
```



ПАТОЛОГИЯ СЕТЧАТКИ PATHOLOGY OF RETINA

test sample has given the following values of the F-measure: ResNet18: 0.985; ResNet50: 1,000; VGG16: 0.940; VGG19: 0.990; GoogleNet: 0.987. Pre-trained network ResNet50 performed best with frozen layers, Adam optimizer, cross-entropy as a loss function, and a training step of 0.000005. **Conclusion**. The use of convolutional neural networks for the automatic detection of Fuchs' dystrophy can be successfully implemented

as part of a doctor's decision support system. ResNet50 showed the best results among all types of models and did not give a single error on the test sample, which indicates the high efficiency of using this network in the classification algorithm for corneal endothelial images.

Keywords: artificial intelligence, Fuchs corneal dystrophy, convolutional neural networks

For quoting: Shukhaev S.V., Mordovtseva E.A., Pustozerov E.A., Kudlakhmedov S.S. Application of convolutional neural networks to define Fuchs endothelial dystrophy. Fyodorov Journal of Ophthalmic Surgery. 2022;4S: 70–76. doi: 10.25276/0235-4160-2022-4S-70-76 Corresponding author: Sergei V. Shukhaev, shukhaevsv@gmail.com

АКТУАЛЬНОСТЬ

а последние годы в офтальмологии вырос интерес к искусственному интеллекту (ИИ), в особенности к сетям на основе глубокого обучения [1-3]. ИИ применяется для повышения эффективности процесса лечения за счет более точной диагностики, автоматизации процессов принятия решений и помощи в других аспектах повседневной деятельности врача [2-4]. Для решения задач, связанных с компьютерными изображениями, наиболее популярным типом глубоких нейронных сетей стали сверточные нейронные сети [5-7]. Задача данной сети – распознавать определенные характеристики изображения. По данным ImageNet, сверточные сети в последние годы занимают первое место в конкурсе по распознаванию образов среди остальных искусственных нейронных сетей и превосходят другие архитектуры в точности на 10-15% [8]. Для решения вопроса о наличии и степени выраженности заболевания врачу важно иметь поддержку в виде системы автоматизированной диагностики [3]. На основе автоматических методов классификации изображений возможна диагностика дистрофий роговицы. Наибольшую распространенность и клиническую значимость среди генетически детерминированных эндотелиальных дистрофий имеет эндотелиальная дистрофия роговицы Фукса [9-11]. В 1911 г. А. Vogt подробно описал биомикроскопическую картину начальных клинических проявлений заболевания и предложил термин «cornea guttata» для описания характерных эндотелиальных изменений роговицы в виде капель или выпячиваний, которые при увеличении напоминают вид «булыжной мостовой» или «запотелого стекла» [12]. Современная диагностика эндотелиальной дистрофии Фукса осуществляется путем визуального анализа при биомикроскопическом исследовании задних слоев роговицы и оценки состояния слоя эндотелиальных клеток на снимках [13-15]. Методы машинного обучения представляют собой перспективный подход, который может стать дополнительным инструментом диагностики и принятия решения для офтальмолога, позволяя вовремя выявлять пациентов с дистрофией Фукса даже на ранней стадии заболевания, когда клинические признаки могут быть не выражены.

ЦЕЛЬ

Оценить применение сверточных нейронных сетей для автоматического определения дистрофии Фукса.

МАТЕРИАЛ И МЕТОДЫ

Была произведена выборка случайных (n=700) биомикроскопических снимков роговицы, полученных при помощи эндотелиального микроскопа (Tomey EM-3000), из базы данных Санкт-Петербургского филиала «МНТК «Микрохирургия глаза» им. акад. С.Н. Федорова» в период с 07.2015 по 04.2021. На первом этапе выполнялось разделение снимков на 2 группы. Первая группа включала в себя снимки с наличием дистрофии Фукса, вторая - норму или другую патологию. Два опытных офтальмохирурга анализировали снимки эндотелия и данные электронной истории болезни. Были изучены данные анамнеза пациентов для уточнения возможной этиологии дистрофии роговицы. Анализировалось описание биомикроскопической картины роговицы, наличие cornea guttata, подтвержденный диагноз дистрофии Фукса или другой патологии. На снимках Tomey EM-3000 оценивали качество, размеры и форму клеток, плеоморфизм, полимегатизм, а также плотность эндотелиальных клеток (ПЭК).

Снимки ПЭК были разделены на три категории: тренировочный, валидационный и тестовый наборы данных. Тренировочный набор включал в себя 600 снимков, 3/4 из которых составляли тренировочную часть, 1/4 – валидационную часть. Тестовый набор включал в себя 100 снимков. Соответственно, тренировочный используется для обучения нейросетевой модели, валидационный – для расчетов ошибки и выбора лучшей модели, тестовый – для проведения финальной оценки точности полученной модели.

Разделение датасета мы произвели таким образом, что в тренировочном и валидационном наборах данных количество снимков с патологией и без патологии были равны при использовании кросс-энтропии в качестве функции потерь. Если их количество не будет равно, сеть будет обучаться неравномерно, и результаты будут неточными.

ПАТОЛОГИЯ СЕТЧАТКИ PATHOLOGY OF RETINA

В данной работе были использованы различные архитектуры сверточных нейронных сетей. Сверточный слой такой сети работает на основе фильтра, который представляет собой матрицу чисел. Этот фильтр также называют ядром свертки. Его задача – распознавать определенные характеристики изображения. Это ядро свертки перемещается вдоль изображения и ищет эти характеристики в разных его частях. Операция свертки заключается в перемножении коэффициентов матрицы ядра и матрицы входных сигналов, затем они суммируются, и число записывается в новую, уменьшенную матрицу. Такая архитектура обеспечивает инвариантность распознавания относительно сдвига объекта.

Функция потерь рассчитывает ошибку между реальными и получаемыми ответами в процессе обучения. Она используется при обучении для настройки весов. В начале обучения нейронной сети данная функция рассчитывает, насколько данный ответ соотносится с реальной меткой данного изображения обучающей выборки.

В качестве функции потерь в нашем исследовании была выбрана кросс-энтропия (Cross-Entropy Loss Function, CELF). С вероятностными случаями она справляется лучше всего, поскольку в ее основе лежит байесовский подход обработки данных [16].

Также важным выбором перед началом проведения процесса обучения является выбор оптимизатора нейронной сети. Обучение нейронной сети происходит с помощью метода обратного распространения ошибки. Он заключается в том, что происходит перенос информации о неверно определенных классах с конца сети на веса, которые находятся внутри сети. Затем другой алгоритм настраивает эти веса таким образом, чтобы улучшить точность сети. Алгоритм, который занимается этим подбором весов, и является оптимизатором. Суть его работы в том, чтобы подобрать такие значения, при которых функция потерь будет минимальна.

Для решения поставленных задач в данном исследовании нами был выбран оптимизатор – Adam. Данный оптимизатор является вариацией стохастического градиентного спуска. Adam является довольно простым в вычислениях алгоритмом, поэтому он не требует много памяти, но при этом показывает хорошую эффективность. Поскольку в качестве входных данных в нашей работе фигурируют изображения, которые занимают достаточно много памяти, использование данного оптимизатора позволяет повысить скорость процесса обучения, не занимая при этом много места в памяти.

Интерпретация выходных данных и оценка точности работы нейронной сети оценивались при помощи критерия F-меры. Данный критерий имеет три параметра: точность, полноту и вес точности. После обучения нейронной сети мы получаем значение F-меры полученной модели. Данная F-мера достигает максимума при полноте и точности, равным единице, и близка к нулю, если один из аргументов близок к нулю. Соответственно, чем выше значение F-меры, тем лучше и точнее работает нейронная сеть. Также в качестве оценки работы данной нейронной сети был использован коэффициент каппа Коэна. Данный коэффициент сравнивает наблюдаемую точность с ожидаемой точностью прогноза класса. Перед запуском обучения нами был выбран дополнительный ряд параметров, которые значительно влияют на данный процесс:

1. Начальное значение генератора случайных чисел (Seed). В данной работе используется seed = 1.

2. Размер выборок для одной итерации (Batch size). Batch size представляет собой выборку из датасета, проходящую через нейронную сеть за одну итерацию. Чем больше эти группы, тем больше места необходимо для них в памяти видеокарты. Начальным значением выборки для обучения разработанной модели было выбрано число 20. Меньшее число увеличит время обучения, а для использования большего числа для большинства коммерчески доступных видеокарт недостаточно памяти графического ускорителя.

3. Эпохи (Epochs). Эпоха представляет собой полный проход всего датасета через нейронную сеть в одну сторону и обратно. Их количество указывает на то, сколько раз модель подверглась воздействию обучения. В конце каждой эпохи меняются веса модели. Одной эпохи недостаточно, поскольку модель считается недообученной, при большом количестве эпохи вычисления занимают значительное время и модель может оказаться переобученной. Для обучения разработанной модели было выбрано число в 200 эпох [17].

В нашем исследовании были протестированы различные архитектуры сверточных нейронных сетей: ResNet18, ResNet50, VGG16, VGG19 и GoogleNet. RestNet18 состоит из 18 слоев и содержит промежуточные связи между ними. RestNet50 имеет архитектуру, аналогичную RestNet18, но содержит 50 слоев. VGG16 состоит из 16 слоев и не имеет промежуточных связей, VGG19 аналогична VGG16, но имеет 19 слоев. GoogleNet обладает параллельными соединениями между блоками слоев.

После определения лучшей архитектуры мы оценили сеть при различных значениях параметров: оптимизатор и скорость обучения.

РЕЗУЛЬТАТЫ

В *таблице 1* отражены данные о количестве обследованных пациентов, количестве эндотелиальных снимков, возрасте и гендерной принадлежности.

Результаты обучения и данные метрик, рассчитанных при проведении обучения моделей нейронных сетей, приведены в *таблице 2*.

Как видно из *таблицы 2*, лучше всего по значениям метрик себя показала модель ResNet50. Она превосходит остальные модели по всем параметрам оценки. Помимо нее хорошие показатели имеет VGG19, однако ее минусом является длительное время обучения. VGG16 обуча-

Применение сверточных нейронных сетей для определения эндотелиальной...

ПАТОЛОГИЯ СЕТЧАТКИ PATHOLOGY OF RETINA

лась дольше, чем сети типа ResNet, и при этом показала результаты хуже, чем у них. Быстрее всего обучилась сеть ResNet18 за счет малого количества слоев и наличия дополнительных связей, однако значение F-метрики у нее меньше, чем у ResNet50 и VGG19. GoogleNet показала результаты приблизительно такие же, как и ResNet18, однако время обучения у нее при этом оказалось больше.

На *рисунке* изображены кривые обучения ResNet50. Как видно из рисунка, количество потерь достаточно быстро снижается за 10 эпох, далее стабилизируется и стремится к 0. Точность и F-мера достигли высоких значений за 75 эпох.

Также нами было изучено, как ведет себя RestNet50 при различных значениях параметров: скорость обучения *(табл. 3)* и оптимизатор *(табл. 4)*.

Изначально при обучении использовалась скорость, равная 0,0000005. Поменяем это число на значение 0,000001. Время обучения при этом сокращается до 36 мин. Значения Epochs сократим до 30, а Batch size до 3. Как видно из *таблицы* 3, чем больше скорость обучения сети ResNet50, тем быстрее проходит обучение, но при этом точность ее не падает.

Далее мы изменили оптимизатор сети на стохастический градиентный спуск (СГС). Как видно из *таблицы 4*, при использовании СГС время обучения сильно не изменилось, однако точность распознавания стала меньше.

Сеть ResNet50 показала лучший результат при использовании предобученной сети на данных ImageNet с замороженными слоями, оптимизатором Adam, кросс-энтропией в качестве функции потерь и шагом обучения 0,000005.

ОБСУЖДЕНИЕ

Применение сверточных нейронных сетей для автоматического определения патологии органа зрения может быть успешно реализовано в составе системы поддержки принятия решения врача [3]. В настоящий момент в доступной отечественной и зарубежной литера-

	Тарлица Т			
Данные о пациентах				
Table 1				
Patient data				
Параметр	Значение			
Parameter	Meaning			
Количество пациентов	350			
Количество эндотелиальных снимков Number of endothelial images	700			
Возраст (лет)	64,5±12,7			
Age (years)	35-87			
Мужской пол, п (%) Male, п (%)	100 (28,5)			
Женский пол, n (%) Female, n (%)	250 (71,5)			
Правый глаз, n (%) Right eye, n (%)	350 (50,0)			
Левый глаз, n (%) Left eye, n (%)	350 (50.0)			

туре нет данных об использовании ИИ при диагностике дистрофии роговицы Фукса.

Большое количество ранних публикаций в области ИИ в офтальмологии посвящено диабетической ретинопатии, при этом основная задача – совершенствование скрининговых исследований диабетической ретинопатии на основе изображений глазного дна [3, 23–25]. Одним из наиболее крупных исследований была работа V. Gulshan и соавт. Используя обучающую выборку EyePACS из 128 175 фундус-снимков и две валидационные выборки EyePACS-1 и Messidor-2, авторы получили высокие показатели чувствительности и специфичности в диагностике умеренной и тяжелой диабетической ретинопатии и диабетического макулярного отека [18].

Данные метрик и результаты обучения нейронных сетей Table 2 Table 2 Меtric data and neural network training results Модель Model Precision Recall Карра F-мера F-measure Время обучения Training time ResNet18 0,985 0,985 0,970 0,985 35 мин 32 сек						Таблица 2
Table :Модель ModelPrecisionRecallКарраF-мера F-measureВремя обучения Training timeResNet180,9850,9850,9700,98535 мин 32 сек	Данные метрик и результаты обучения нейронных сетей					
Metric data and neural network training results Модель Model Precision Recall Карра Карра F-мера F-measure Время обучения Тraining time ResNet18 0,985 0,985 0,970 0,985 35 мин 32 сек						Table 2
Модель Model Precision Recall Карра F-мера F-measure Время обучения Training time ResNet18 0,985 0,985 0,970 0,985 35 мин 32 сек	Metric data and neural network training results					
Model Пессии Карра F-measure Training time ResNet18 0,985 0,985 0,970 0,985 35 мин 32 сек	Модель	Precision	Recall	Kanna	F-мера	Время обучения
ResNet18 0,985 0,985 0,970 0,985 35 мин 32 сек	Model	Trecision	Recall	Карра	F-measure	Training time
	ResNet18	0,985	0,985	0,970	0,985	35 мин 32 сек
ResNet50 1 1 1 1 59 мин	ResNet50	1	1	1	1	59 мин
VGG16 0,94 0,94 0,88 0,94 1 ч 20 мин	VGG16	0,94	0,94	0,88	0,94	1 ч 20 мин
VGG19 0,99 0,99 0,985 0,99 2 ч 54 мин	VGG19	0,99	0,99	0,985	0,99	2 ч 54 мин
GoogleNet 0,987 0,987 0,973 0,987 45 мин 26 сек	GoogleNet	0,987	0,987	0,973	0,987	45 мин 26 сек



Рис. Результаты обучения RestNet50: зависимость значения потерь (сверху), точности (в центре) и F-меры (снизу) от количества эпох. Синим цветом показаны графики для тренировочного набора данных, оранжевым – для валидационного набора данных

Fig. RestNet50 training results: Loss value (top), accuracy (middle) and F-measure (bottom) as a function of the number of epochs. The blue color shows the graphs for the training dataset, orange for the validation dataset

Была показана эффективность ИИ в диагностике и ведении пациентов с возрастной макулярной дегенерацией (ВМД) [26, 27]. Р.М. Burlina и соавт. использовали два алгоритма глубокого обучения для классификации изображений глазного дна – сверточную нейронную сеть архитектуры AlexNet и предобученную универсальную нейронную сеть OverFeat. Была использована база данных AREDS, содержащая 130 000 снимков глазного дна 4613 пациентов. Первый класс состоял из изображений без признаков ВМД или с ранней стадией ВМД, во второй класс входили изображения с промежуточной и далеко зашедшей стадией ВМД. Показатель AUROC составил 0,94–0,96, при этом авторы заключили, что машинный анализ схож по точности с исследованием специалистом офтальмологом [19].

В 2017 г. U. Raghavendra и соавт. исследовали качество классификации изображений глазного дна у пациентов с глаукомой и без нее с помощью сверточных нейронных сетей. Авторы использовали 1426 изображений (589 от здоровых лиц, 837 от больных глаукомой). В обучающей выборке использовали 70% изображений, при этом получены высокие показатели (чувствительность и специфичность 98%) [20].

В 2015 г. Х. Gao и соавт. исследовали эффективность сверточно-рекурсивных нейронных сетей при классификации изображений, полученных с помощью щелевой лампы, для определения степени выраженности ядерной катаракты [21].

На сегодняшний день имеется большое количество разработок в области ИИ применительно к процессу диагностики и хирургии кератоконуса [4]. В 2017 г. R. Ambrósio и соавт. исследовали эффективность ряда методов машинного обучения в автоматизированной классификации данных, полученных с помощью кератотопографии и исследования биомеханических свойств роговицы. Был выведен томограммо-биомеханический индекс, который показал высокие результаты по чувствительности и специфичности для дифференцировки между нормой и субклиническим кератоконусом [22].

Результаты обучения ResNet50 при разных скоростях обучения

Таблица З

ПАТОЛОГИЯ СЕТЧАТКИ

PATHOLOGY OF RETINA

Table 3

ResNet50 training results at different learning rates

Скорость обучения Learning rate	Epochs	Batch size	F-мера F-measure	Время обучения Training time
0,000001	30	3	1	36 мин 36 min
0,00005	25	3	1	30 мин 30 min
0,00001	10	3	1	11 мин 11 min

Таблица 4

Результаты обучения ResNet50 при использовании разных оптимизаторов

Table 4

ResNet50 training results using different optimizers

Оптимизатор Optimizer	Epochs	Batch size	F-мера F-measure	Время обучения Training time
Adam	10	3	1	11 мин 11 min
СГС	10	3	0.985	11 мин 30 сек 11 min 30 sec

В настоящее время ИИ все чаще применяется для диагностики и лечения различной офтальмопатологии. Однако наше исследование - первый опыт использования ИИ для определения дистрофии роговицы Фукса.

ЗАКЛЮЧЕНИЕ

Применение сверточных нейронных сетей для автоматического определения дистрофии Фукса может быть успешно реализовано в составе системы поддержки принятия решения врача. ResNet50 показала лучшие результаты среди всех типов моделей и на тестовой выборке не выдала ни одной ошибки, что говорит о высокой эффективности использования данной сети в алгоритме классификации снимков эндотелия роговицы.

ЛИТЕРАТУРА/REFERENCES

1. Kappor R, Walters SP, Al-Aswad LA. The current state of artificial intelligence in ophthalmology. Surv Ophthalmol. 2019;64(2): 233-240. doi: 10.1016/j.survophthal.2018.09.002

2. Lakhani P, Prater AB, Hutson RK, Andriole KP, Dreyer KJ, Morey J, et al. Machine learning in radiology: applications beyond image interpretation. J Am Coll Radiol. 2018;15(2): 350-359. doi: 10.1016/j.jacr. 2017.09.044

3. Гарри Д.Д., Саакян С.В., Хорошилова-Маслова И.П., Цыганков А.Ю., Никитин О.И., Тарасов Г.Ю. Методы машинного обучения в офтальмологии. Обзор литературы. Офтальмология. 2020;17(1): 20-31. doi: 10.18008/1816-5095-2020-1-20-31 [Garry DD, Sahakyan SV, Khoroshilova-Maslova IP, Tsygankov AYu, Nikitin OI, Tarasov GYu. Machine learning methods in ophthalmology. Literature review. Ophthalmology in Russia. (In Russ.)]

4. Малюгин Б.Э., Сахнов С.Н., Аксенова Л.Е., Мясникова В.В. Применение искусственного интеллекта в диагностике и хирургии кератоконуса: систематический обзор. Офтальмохирургия. 2022;1: 77–96. [Malyugin BE, Sakhnov SN, Aksenova LE, Myasnikova VV. The use of artificial intelligence in the diagnosis and surgery of keratoconus: a systematic review. Fyodorov Journal of Ophthalmic Surgery. 2022;1: 77-96. (In Russ.)] doi: 10.25276/0235-4160-2022-1-77-96

5. Kotsiantis SB. Supervised machine learning: a review of classification techniques. Informatica. 2007;31: 249-268.

6. Zhang Z. Improved Adam optimizer for deep neural networks. 2018 IEEE/ACM 26th International Symposium on Quality of Service, 2018: 1–2.

7. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. IEEE Conference on computer vision and pattern recognition. 2016: 770-778.

8. Kaiming H. Delving deep into rectifiers: surpassing humanlevel performance on ImageNet classification. 2015 IEEE International Conference on Computer Vision. 2015: 1109-1135.

9. Adamis AP, Filatov V, Tripathi BJ, Tripathi RC. Fuchs' endothelial dystrophy of the cornea. Surv Ophthalmol. 1993;38(2): 147-168.

10. Friedenwald H, Friedenwald JS. Epithelial dystrophy of the cornea. Br J Ophthalmol. 1925;9(1): 14-20.

11. Fuchs E. Dystrophia epithelialis corneae. Albrecht Von Graefe Arch Klin Exp Ophthalmol. 1910;76: 478-508.

12. Vogt A. Weitere Ergebnisse der Spaltlampenmikroskopie des vorden Bulbusabschnittes. Graefes Arch Clin Exp Ophthalmol.1921;106: 6–103.

13. Cross HE, Maumenee AE, Cantolino SJ. Inheritance of Fuchs' endothelial dystrophy. Arch Ophthalmol. 1971;85: 268–272.

14. Gottsch JD, Sundin OH, Rencs EV, Emmert DG, Stark WJ, et al. Analysis and documentation of progression of Fuchs corneal dystrophy with retroillumination photography. Cornea. 2006;25(4): 485–489.

15. Rosenblum P, Stark WJ, Maumenee IH, Hirst LW, Maumenee AE. Hereditary Fuchs' Dystrophy. Am J Ophthalmol. 1980;90: 455–462.

16. Qian N. On the momentum term in gradient descent learning algorithms. Neural Networks: the official journal of the international neural. Neural Networks. 1999;12: 145–151.

17. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. IEEE Conference on computer vision and pattern recognition. 2016: 770–778. doi: 10.1109/CVPR.2016.90

18. Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. JAMA. 2016;316(22): 2402. doi: 10.1001/jama.2016.17216

19. Burlina PM, Joshi N, Pekala M, Pacheco KD, Freund DE, Bressler NM. Automated grading of age-related macular degeneration from color Fundus images using deep convolutional neural networks. JAMA Ophthalmology. 2017;135(11):1170. doi: 10.1001/jamaophthalmol.2017.3782.

20. Raghavendra U, Fujita H, Bhandary SV, Gudigar A, Tan JH, Acharya UR. Deep convolution neural network for accurate diagnosis of glaucoma using digital fundus images. Inform Sci. 2018; 441(1): 41–49. doi: 10.1016/j.ins.2018.01.051

21. Gao X, Lin S, Wong TY. Automatic feature learning to grade nuclear cataracts based on deep learning. IEEE Transactions on Biomedical Engineering, 2015;62(11): 2693–2701. doi: 10.1109/TBME.2015.2444389

22. Ambrósio R, Lopes BT, Faria-Correia F, Salomão MQ, Bühren J, et al. Integration of Scheimpflug-Based corneal tomography and biomechanical assessments for enhancing ectasia detection. J Refract Surg. 2017;33(7): 434–443. doi: 10.3928/1081597X-20170426-02

23. Abràmoff MD, Folk JC, Han DP, Walker JD, et al. Automated analysis of retinal images for detection of referable diabetic retinopathy. JAMA Ophthalmology. 2013;131(3): 351. doi: 10.1001/jamaophthalmol.2013.1743

24. Abràmoff MD, Lou Y, Erginay A, Clarida W, Amelon R, Folk JC, Niemeijer M. Improved automated detection of diabetic retinopathy on a publicly available dataset through integration of deep learning. Invest Opthalmol Vis Sci. 2016;57(13):5200. doi: 10.1167/iovs.16-19964

25. Takahashi H, Tampo H, Arai Y, Inoue Y, Kawashima H. Applying artificial intelligence to disease staging: deep learning for improved staging of diabetic retinopathy. PLoS One. 2017;12(6): e0179790. doi: 10.1371/journal.pone.0179790

26. Serrano-Aguilar P, Abreu R, Antón-Canalís I, Guerra-Artal C, Ramallo-Fariña Y, Gómez-Ulla F, Nadal J. Development and validation of a computeraided diagnostic tool to screen for age-related macular degeneration by optical coherence tomography. Br J Ophthalmol. 2011;96(4): 503–507. doi: 10.1136/ bjophthalmol-2011-300660

27. Treder M, Lauermann JL, Eter N. Automated detection of exudative age-related macular degeneration in spectral domain optical coherence tomography using deep learning. Graefes Arch Clin Exp Ophthalmol. 2017;256(2): 259–265. doi: 10.1007/s00417-017-3850-3

Информация об авторах

Сергей Викторович Шухаев, к.м.н., врач-офтальмолог, shukhaevsv@gmail. com, https://orcid.org/0000-0001-7047-615X

Елизавета Антоновна Мордовцева, врач-офтальмолог, liza_mordovtseva@mail.ru, https://orcid.org/0000-0001-7495-1181

Евгений Анатольевич Пустозеров, кт.н., pustozerov.e@gmail.com, https:// orcid.org/0000-0001-8109-1319

Шакир Шавкатович Кудлахмедов, аспирант, врач-офтальмолог, shakir47@yandex.ru, https://orcid.org/0000-0001-6047-3828

Information about the authors

Sergei V. Shukhaev, PhD in Medicine, Ophthalmologist, shukhaevsv@gmail. com, https://orcid.org/0000-0001-7047-615X

Elizaveta A. Mordovtseva, Ophthalmologist, liza_mordovtseva@mail.ru, https://orcid.org/0000-0001-7495-1181

Evgenii A. Pustozerov, PhD in Engineering, pustozerov.e@gmail.com, https://orcid.org/0000-0001-8109-1319

Shakir Sh. Kudlakhmedov, Postgraduate Doctor, Ophthalmologist, shakir47@ yandex.ru, https://orcid.org/0000-0001-6047-3828

Вклад авторов в работу:

С.В. Шухаев: существенный вклад в концепцию и дизайн работы, окончательное утверждение версии, подлежащей печати.

Е.А. Мордовцева: сбор, анализ и обработка материала, написание текста, редактирование.

E.A. Пустозеров: существенный вклад в концепцию и дизайн работы, сбор, анализ и обработка материала, статистическая обработка данных, написание текста.

Ш.Ш. Кудлахмедов: сбор, анализ и обработка материала, написание текста.

Authors' contribution:

S.V. Shukhaev: significant contribution to the concept and design of the work, final approval of the version to be published.

E.A. Mordovtseva: collection, analysis and processing of material, writing, editing,

E.A. Pustozerov: significant contribution to the concept and design of the work, collection, analysis and processing of material, statistical data processing, writing. **Sh.Sh. Kudlakhmedov:** collection, analysis and processing of material, writing.

Финансирование: Авторы не получали конкретный грант на это исследование от какого-либо финансирующего агентства в государственном, коммерческом и некоммерческом секторах.

Согласие пациента на публикацию: Письменного согласия на публикацию этого материала получено не было. Он не содержит никакой личной идентифицирующей информации.

Конфликт интересов: Отсутствует.

Funding: The authors have not declared a specific grant for this research from any funding agency in the public, commercial or not-for-profit sectors.

Patient consent for publication: No written consent was obtained for the publication of this material. It does not contain any personally identifying information.

Conflict of interest: There is no conflict of interest.

Поступила: 31.10.2022 Переработана: 15.11.2022 Принята к печати: 22.12.2022

Originally received: 31.10.2022 Final revision: 15.11.2022 Accepted: 22.12.2022