

Раздел 2 МОДЕЛИ, СИСТЕМЫ, СЕТИ В ТЕХНИКЕ

Section 2 MODELS, SYSTEMS, NETWORKS IN THE TECHNIQUE

УДК 004.032.26
doi: 10.21685/2227-8486-2023-4-7

ДИАГНОСТИКА ДИАБЕТИЧЕСКОЙ РЕТИНОПАТИИ С ПОМОЩЬЮ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

Д. С. Шишкина¹, В. И. Горбаченко², М. А. Щербаков³

^{1, 2, 3} Пензенский государственный университет, Пенза, Россия
¹ shishikina.2560@mail.ru, ² gorvi@mail.ru, ³ mashcherbakov@yandex.ru

Аннотация. *Актуальность и цели.* В работе рассматривается проблема диагностики диабетической ретинопатии. Целью исследования является создание программного обеспечения для облегчения диагностики диабетической ретинопатии. *Материалы и методы.* В качестве исходных данных для диагностики диабетической ретинопатии был использован общедоступный набор снимков глазного дна с сайта Kaggle, для работы с данными изображениями применена сверточная нейронная сеть Inception v3. Для оценки качества сети вычислены метрики качества (прецизионность, полнота и F₁-мера). *Результаты.* Осуществлено обучение сверточной нейронной сети на снимках глазного дна с признаками диабетической ретинопатии для диагностики по изображению заболевания и степени его развития. Проведены тестирование сети и оценка ее качества. *Выводы.* Сеть классифицирует изображения в соответствии с общепринятой классификацией диабетической ретинопатии в зависимости от степени ее развития. Сеть имеет способность к классификации и может быть доработана экспериментальным путем для возможности ее дальнейшего внедрения в профессиональную врачебную деятельность.

Ключевые слова: диабетическая ретинопатия, диагностика диабетической ретинопатии, распознавание изображений, нейронные сети, сверточные нейронные сети, задача классификации

Для цитирования: Шишкина Д. С., Горбаченко В. И., Щербаков М. А. Диагностика диабетической ретинопатии с помощью сверточной нейронной сети // Модели, системы, сети в экономике, технике, природе и обществе. 2023. № 4. С. 114–132. doi: 10.21685/2227-8486-2023-4-7

DIABETIC RETINOPATHY DIAGNOSIS USING A CONVOLUTIONAL NEURAL NETWORK

D.S. Shishikina¹, V.I. Gorbachenko², M.A. Shcherbakov³

^{1, 2, 3} Penza State University, Penza, Russia

¹ shishikina.2560@mail.ru, ² gorvi@mail.ru, ³ mashcherbakov@yandex.ru

Abstract. *Background.* The paper deals with the problem of diagnosing diabetic retinopathy. The aim of the work is to create software to facilitate the diagnosis of diabetic retinopathy. *Materials and methods.* A publicly available set of ocular fundus images from Kaggle website was used as initial data for diabetic retinopathy diagnosis. Inception v3 convolutional neural network was used to work with these images. Quality metrics (precision, completeness and F1-measure) were calculated to assess the quality of the network. *Results.* Training of a convolutional neural network on ocular fundus images with signs of diabetic retinopathy for image-based diagnosis of the disease and its degree of development was carried out. The network was tested and its quality was evaluated. *Conclusions.* The network classifies images according to the generally accepted classification of diabetic retinopathy depending on the degree of its development. The network has the ability to classify and can be finalized experimentally for the possibility of its further implementation in professional medical activity.

Keywords: diabetic retinopathy, diagnosis of diabetic retinopathy, image recognition, neural networks, convolutional neural networks, classification task

For citation: Shishikina D.S., Gorbachenko V.I., Shcherbakov M.A. Diabetic retinopathy diagnosis using a convolutional neural network. *Modeli, sistemy, seti v ekonomike, tekhnike, prirode i obshchestve* = *Models, systems, networks in economics, technology, nature and society*. 2023;(4):114–132. (In Russ.). doi: 10.21685/2227-8486-2023-4-7

Введение

Диабетическая ретинопатия (ДР) – хроническое заболевание, являющееся одним из наиболее распространенных и опасных осложнений сахарного диабета. Данное заболевание выражается диабетической микроангиопатией, другими словами, поражением сетчатки глаза посредством нарушения работы микрососудистой системы глаза [1, 2]. При наличии сахарного диабета и сопутствующего ему нарушения общего обмена веществ в организме так называемый гемато-ретиальный барьер (совокупность эндотелиальных клеток внутренней оболочки сосудов сетчатки для внутренних слоев сетчатки или совокупность клеток пигментного эпителия сетчатки для внешних слоев), который предотвращает попадание в сетчатку глаза крупных молекул, разрушается, что ведет к сбою в работе микрососудистой системы и искажению структуры сосудов, что далее способствует развитию различных патологий [3].

Связь сахарного диабета и диабетической ретинопатии говорит о массовости последней, так как сахарный диабет является достаточно распространенным заболеванием: в России на 2022 г. зарегистрировано более 5 млн человек с данным диагнозом, в мире – около 422 млн человек. Диабетическая ретинопатия наблюдается у большей части людей с диабетом первого типа и у значительной части людей с диабетом второго типа [4, 5].

Диабетическая ретинопатия является прогрессирующим заболеванием, и Всемирной организацией здравоохранения (ВОЗ) была введена классификация [1, 2] диабетической ретинопатии в зависимости от степени ее развития:

– непролиферативная ретинопатия, которая выражается мелкими кровоизлияниями и отеком сетчатки в центральной части глазного дна;

– препролиферативная ретинопатия, которая выражается венозными аномалиями (изменение вида и структуры стенок сосудов, например перекручивание сосудов), наличием экссудатов (воспалительных выделений) и экстравазатов (кровоизлияний);

– пролиферативная ретинопатия, которая выражается обильными кровоизлияниями в стекловидное тело глаза, появлением фиброзной ткани (волокнистая соединительная ткань) и неоваскуляризацией, т.е. разрастанием кровеносных сосудов в те места, в которых их не должно быть (например, разрастание сосудов в радужной оболочке глаза приводит к глаукоме). Кроме того, появившиеся в результате неоваскуляризации сосуды являются достаточно хрупкими, и разрушение их стенок тоже приводит к кровоизлияниям.

Дегенерация микрососудистой системы сетчатки происходит достаточно быстро. На рис. 1 представлены снимки глазного дна с наличием признаков диабетической ретинопатии [1].




Рис. 1. Снимок глазного дна:

а – наличие признаков диабетической ретинопатии;

б – прогрессирующее заболевание

Снимки сделаны с разницей в восемь месяцев. За данный период получило развитие явление неоваскуляризации; кроме того, на втором снимке можно заметить достаточно обильное кровоизлияние, что говорит о весьма быстром переходе заболевания в пролиферативную стадию.

Кроме своей массовости и скорости прогрессирования диабетическая ретинопатия также опасна последствиями ее несвоевременного лечения. Чем позже данное заболевание будет диагностировано, тем больше необратимых патологий возникнет в сетчатке пациента. Диабетическая ретинопатия крайне сильно снижает остроту зрения, и отсутствие лечения или его позднее начало могут привести к полной слепоте пациента.

Учитывая тяжелые последствия заболевания, целесообразно сосредоточиться на улучшении качества диагностики, так как диагностика диабетической ретинопатии на ранней стадии может помочь вовремя купировать развитие заболевания и сохранить пациенту зрение. Диагностика диабетической ретинопатии чаще всего осуществляется посредством анализа снимков

глазного дна на наличие признаков заболевания. Однако выявить на изображении признаки диабетической ретинопатии на ранней стадии, наиболее благоприятной для начала качественного лечения, практически невозможно. Симптомы данного заболевания на ранних этапах неразличимы для человеческого взгляда, и постановкой верного диагноза диагностикой должен заниматься либо консилиум врачей, либо офтальмолог с очень большим опытом работы с диабетиками, что для большинства больниц недоступно, особенно с учетом большого количества людей с сахарным диабетом. Отсюда следует необходимость автоматизировать диагностику диабетической ретинопатии, чтобы снизить нагрузку на врачей, упростить раннюю диагностику и повысить ее точность.

За рубежом уже проводились исследования данного вопроса. Наиболее известной является работа команды разработчиков Google [6–9], в основе которой лежит сеть Inception v3. Публикация исследования произошла в 2016 г., однако усовершенствования модели ведутся до сих пор, и она еще не введена в эксплуатацию. Модель Google достигла средней точности для пяти классов в 88,4 % [9]. В работе [10] предложен подход для решения данной задачи, основанный на построении гистограмм дискриминативной и генеративной патологий и объединении их с представлениями признаков, извлеченными из полносвязных слоев сверточной нейронной сети. В работе [11] применен подход, основанный на двухступенчатом трансферном обучении, где первый слой предварительно обученной сети повторно инициализируется с использованием областей интереса поражений (выделенных локальных областей с повреждениями сетчатки). Затем, после обучения сети на локальных областях, осуществляется обучение на полноценном изображении. В качестве предварительно обученных сетей использовались VGG19, ResNet152 и DPN107, обученные на наборе данных ImageNet [12]. Лучший результат дала сеть ResNet152, средняя точность для пяти классов для двух различных тестовых наборов – 99,73 % и 98,88 % соответственно. В работе [13] распознавание степени развития диабетической ретинопатии осуществляется с использованием сети Efficientnet-B0 и трансферного обучения (transfer learning). Метод позволяет распознавать изображения без признаков ДР с точностью 98,3 %, однако при диагностике стадий развития ДР присутствуют затруднения из-за схожести некоторых классов. Для четырех стадий (от самой ранней до самой поздней) достигнута точность 57,6 %, 89,1 %, 58,8 %, 70,3 % соответственно. В работе [14] создана оригинальная сверточная нейронная сеть на основе метода главных компонент. Для двух различных тестовых наборов была достигнута средняя точность в 98,21 % и 94,22 % соответственно. В работе [15] представлены две сверточные нейронные сети, одна из которых различала снимки без признаков диабетической ретинопатии и с признаками диабетической ретинопатии, а вторая отличала раннюю стадию от более поздних. Точность для каждой из моделей – 98 % и 91 % соответственно. В работе [16] решалась задача для двух классов (наличие и отсутствие ДР) в системе MATLAB с помощью сверточной нейронной сети, состоящих из трех последовательно соединенных модулей из сверточного слоя, слоя пакетной нормализации, функции активации ReLU и слоя пулинга max-pooling. Сеть на трех тестовых наборах дала следующие показатели точности: 100 %, 99,495 % и 97,55 % соответственно. В исследовании [22] применялась гибридная сеть на основе сверточной

нейронной сети VGG16 и капсульной сети. Средняя точность для многоклассовой задачи составила 75,81 %, для бинарной задачи – 95,50 %. В исследовании [18] рассмотрено два варианта сети: гибридная сеть, объединяющая сверточную сеть VGG16 и классификатор градиентного бустинга XGBoost, и сверточная сеть DenseNet121. Гибридная сеть достигла точности многоклассовой классификации 79,50 %, модель DenseNet121 достигла точности 97,30 %. В работе [19] белорусских исследователей для классификации снимков с ДР использовались сети VGG16 и VGG19. В основном рассматривался подбор оптимального размера изображения для достижения максимальной точности, показатели точности не приводятся, но отмечается достаточно высокая точность классификации на два класса и недостаточная точность при определении степени тяжести ДР. В обзорных статьях [20–23] рассматриваются и некоторые другие варианты решения данной задачи с помощью нейронных сетей.

В России известно несколько исследований, посвященных применению нейронных сетей для диагностики диабетической ретинопатии. В работе [24] разработана оригинальная сверточная нейронная сеть. Обучение и тестирование модели осуществлялось для многоклассовой (пять классов) и бинарной (наличие и отсутствие ДР) задач. Максимальная точность при решении многоклассовой задачи составила 57,4 %, максимальная точность для бинарной задачи составила 80,7 %. В работе [25] применялась сеть ResNet50. В данном исследовании также решалась бинарная задача. Максимальная чувствительность на тестовой выборке составила 65 %.

Таким образом, проблема автоматизации диагностики диабетической ретинопатии является актуальной, и в мире существует множество исследований и разработок, посвященных решению данной задачи. Однако в России на данный момент эта проблема не приобрела достаточную известность, что заметно по числу опубликованных работ. Причем во всех работах решалась бинарная задача выявления здоровых пациентов и пациентов с диабетической ретинопатией, т.е. просто определялся сам факт наличия ДР без учета стадии заболевания, при том что наиболее важно научиться выявлять конкретно раннюю стадию, и только в одной была попытка решить многоклассовую задачу, которая дала относительно невысокие результаты.

В связи с этим целью настоящего исследования является разработка модели сверточной нейронной сети для решения многоклассовой задачи распознавания стадии развития диабетической ретинопатии.

Материалы и методы

Так как работать необходимо с изображениями, для решения поставленной задачи по автоматизации диагностики диабетической ретинопатии целесообразно использовать сверточную нейронную сеть.

Для обучения и тестирования разработанной модели сверточной сети использован открытый набор данных Diabetic Retinopathy Unzipped, содержащий снимки глазного дна с признаками диабетической ретинопатии, с сайта Kaggle [26]. Набор содержит 34 882 примера, общий размер набора – 35 Гб. Примеры представляют собой снимки глазного дна и левого, и правого глаза каждого из пациентов. Снимки получены с разных моделей камер и ракурсов, поэтому на некоторых снимках могут присутствовать дефекты и искажения: они могут быть инвертированы, перевернуты, имеют разный исходный размер.

Снимки представлены в формате jpeg и имеют метки от 0 до 4: 0 – отсутствие диабетической ретинопатии, 4 – пролиферативная стадия, 3 – препролиферативная стадия, 1 и 2 – два этапа развития непролиферативной стадии.

Данный набор не является сбалансированным. Из 34 882 примеров более 20 000 относятся к классу 0, остальное количество распределено между другими классами. Использование набора в таком виде нецелесообразно, так как это приведет к неизбежному заучиванию наиболее представленного класса, поэтому в процессе решения исходной задачи решалась также задача балансировки набора. Малые по числу примеров классы были дополнены с помощью метода аугментации – получения новых данных посредством применения к исходным данным различных преобразований.

Для аугментации использована библиотека для языка Python – Augmentor [27]. Она содержит функции преобразования изображений и позволяет записывать сгенерированные изображения в каталог на указанном диске. Это достаточно удобно для использования полученных примеров в других моделях, что проблематично при использовании аугментации во встроенном генераторе Keras [34], так как там новые примеры формируются в ходе обучения, увеличивая время обучения. Набор разделен в соотношении: 15 000 примеров для тренировочной выборки (по 3000 от каждого класса), 5250 и 5250 для валидационной и тестовой (по 1050 от каждого класса в каждой из этих двух выборок). Классы во всех выборках должны быть представлены равным числом примеров. Таким образом, нужно было иметь по 5100 изображений каждого класса (всего 25 500). Классы 0 и 2 были представлены достаточным числом примеров, так что дополнение до 5100 проводилось для классов 1 (к 2420 примерам было добавлено еще 2680), 3 (к 870 было добавлено 4230) и 4 (к 708 было добавлено 4392). Для аугментации использованы преобразования: случайное искажение, отражение лево/право, отражение верх/низ, поворот. После балансировки было осуществлено разделение изображений на тренировочную, валидационную и тестовую выборки в выбранном соотношении. Также данные необходимо привести к определенному размеру (был выбран размер 224×224 , соответствующий размеру изображений, которые применяются для обучения многих известных сверточных архитектур) [12]. Кроме того, для упрощения обучения проведено сглаживание шума на изображениях средствами библиотеки CV [29]: взвешенного сложения (наложения) с вариантом этого же изображения с размытием по Гауссу. На рис. 2 представлен пример изображения из набора без сглаживания шума и с сглаживанием шума. Видно, что кровеносные сосуды и экссудаты на изображении стали более различимыми.




Рис. 2. Пример снимка из набора:
а – без сглаживания шума; б – с сглаживанием шума

Для задачи, рассматриваемой в данной работе, использована модель сверточной нейронной сети на основе архитектуры Inception v3 [30]. Архитектура Inception v3 применена в самом известном исследовании диагностики диабетической ретинопатии с помощью сверточных нейронных сетей – исследовании Google [6–9].

Использована Inception v3, а не более новая Inception v4, потому что реализация модели в настоящей работе осуществлялась средствами библиотеки машинного обучения Keras [31–32] для языка Python, а данная библиотека не содержит реализации архитектуры Inception v4. Библиотека Keras, кроме Inception v3, содержит также реализацию архитектуры Inception-ResNet v2, которая обладает вычислительной эффективностью, аналогичной Inception v4 [33], однако является достаточно большой (215 Мб против 92 Мб Inception v3), имеет большую топологическую глубину (449 против 189) и число параметров (55,9 млн против 23,9 млн), что при доступных вычислительных ресурсах затруднит обучение. При этом Inception v3 дает точность (на наборе ImageNet), меньшую точности Inception-ResNet v2 приблизительно на 2 % [34]. По сравнению с другим вариантом архитектуры, который применялся исследователями для решения данной задачи, – ResNet – Inception v3 тоже выигрывает по размерам и числу параметров и обеспечивает точность (на том же наборе ImageNet), большую, чем точность ResNet50, ResNet101 и ResNet152, также реализованных в Keras. [34]. Кроме того, Inception v3 по сравнению с ResNet проще в обучении.

Сеть Inception v3 относится к семейству сетей Inception, в которое входит известная сеть GoogLeNet (другое название – Inception v1). Основной отличительной особенностью сетей данного типа является наличие в сети модулей Inception, состоящих из нескольких сверток разных размеров и субдискретизации по максимальному значению, которые выполняются параллельно. Это позволяет выделять признаки на различных уровнях детализации и формировать ключевые признаки для распознавания изображения. Также это наделяет сеть определенной гибкостью: заранее неизвестно, фильтры каких размеров необходимы для оптимально точного выделения ключевых признаков, и попытка применить какой-либо фиксированный набор фильтров может привести либо к недостаточному обобщению, либо к чрезмерному увеличению количества параметров сети. В каждом модуле Inception к входным картам признаков одновременно применяются фильтры разных размеров, и, так как все фильтры являются обучаемыми, сеть сама может определять, какой фильтр будет влиять на выход в большей степени (при конкатенации данных после осуществления свертки каждым из фильтров). Использование различных фильтров на разных слоях позволяет в итоге усилить различия в масштабах форм объектов на изображении, что улучшает распознавание.

Архитектуры GoogLeNet и Inception v3 во многом похожи, и главным отличием Inception v3 является замена в модулях Inception сверток больших размеров последовательностями сверток меньших размеров, а также наличие асимметричных (прямоугольных) сверток (свертка, например, 3×3 заменялась свертками 1×3 и 3×1). Данный подход увеличил производительность сети. Кроме того, банки фильтров в модулях были расширены, так как увеличение их глубины могло бы привести к чрезмерной потере информации. Оригинальный модуль Inception представлен на рис. 3. Все три вида модулей сети Inception v3 представлены на рис. 4 [30]. Архитектура Inception v3 содержит также блок уменьшения размера сетки (grid size reduction) [30], представленный на рис. 5.




Рис. 3. Оригинальный модуль Inception




Рис. 4. Модули сети Inception v3:

a – замена крупных сверток последовательностью мелких (модуль А); *б* – добавление прямоугольных сверток (модуль Б); *в* – расширение банка фильтров (модуль В)




Рис. 5. Блок уменьшения размера сетки

Упрощенная архитектура сети Inception v3 [35] показана на рис. 6.




Рис. 6. Архитектура сети Inception v3

Блок Stem включает в себя три последовательно идущих слоя свертки, слой пулинга по максимальному значению, два слоя свертки и снова слой пулинга по максимальному значению. В сети Inception v3 после сверточных слоев применяется функция активации ReLU (rectified linear unit) [36], которая имеет вид $f(s) = \max(0, s)$, где s – выход сверточных слоев. Сеть Inception v3 не содержит на выходе полносвязных слоев. После последнего модуля Inception применяется субдискретизация по среднему значению, слой dropout, затем полносвязный слой с 1000 скрытых нейронов (соответствует набору ImageNet), последний слой – функция активации softmax [36] вида

$$f(s_i) = e^{s_i} / \sum_{j=1}^n e^{s_j},$$

где $f(s_i)$ – выход i -го нейрона; s_i – взвешенная сумма i -го нейрона; n – число нейронов выходного слоя.

В работе использована предобученная сеть Inception v3, т.е. использовались веса сети после обучения на наборе ImageNet. Также была применена так называемая тонкая настройка [34] – добавление к выходу основной сети полносвязных слоев (в том числе слоя классификации для нужного числа классов), для которых осуществлялось дальнейшее обучение (трансферное обучение). Было добавлено два слоя: один с функцией активации ReLU, а классификационный слой – с функцией активации softmax. В качестве регуляризатора использован слой dropout [35] с заданной вероятностью исключения нейронов 0,5, расположенный перед слоем классификации.

Для препроцессорной обработки применены генераторы Keras [28]. Для меток был задан параметр 'categorical', который указывает на то, что генератор будет возвращать метки, закодированные с помощью One-Hot Encoding [36], т.е. цифры в коде меток заменялись вектором из элементов, содержащим одну единицу среди нулей. Размер пакетов обучающей выборки для мини-пакетного обучения задан равным 32. В качестве оптимизатора для обучения модели выбран стохастический градиентный спуск [37] – один из наиболее распространенных алгоритмов, применяемых при работе с нейронными сетями. В качестве функции потерь использована типичная для задач классификации категориальная перекрестная энтропия [38]

$$L = - \sum_{i=1}^n \sum_{j=1}^k t_j^{(i)} \ln y_j^{(i)},$$

где $t_j^{(i)}$ – требуемое (целевое) значение выхода j сети при подаче примера i ; $y_j^{(i)}$ – реальное значение выхода j сети при подаче примера i ; k – число выходов сети; n – число примеров в эпохе обучения.

Качество модели оценивалось посредством вычисления соответствующих метрик качества [39] для классификационных моделей: точности (accuracy), прецизионности (precision), полноты (recall) и F_1 -меры. Формулы данных метрик основываются на применении матрицы ошибок (confusion matrices), в простейшем виде отражающей соотношение верно и ложно классифицированных примеров. На рис. 7 представлена матрица ошибок для бинарной классификации, где TP – истинноположительные примеры (все правильно классифицированные примеры, относящиеся к положительному

классу), TN – истинноотрицательные (все правильно классифицированные примеры, относящиеся к отрицательному классу), FP – ложноположительные (все примеры, относящиеся к отрицательному классу и классифицированные как положительные), FN – ложноотрицательные (все примеры, относящиеся к положительному классу и классифицированные как отрицательные).

Confusion Matrix		Prediction	
		Positive	Negative
Actual	Positive	TP	FN
	Negative	FP	TN

Рис. 7. Матрица ошибок для бинарной классификации

Для решаемой задачи многоклассовой классификации были построены матрицы ошибок для каждого класса, представляющие соотношение между реальными и предсказанными значениями для каждого класса.

Метрика под названием точность (ассигура) отражает долю всех правильно классифицированных примеров

$$accuracy = \frac{\sum TP + \sum TN}{all}.$$

Данная метрика не обладает достаточной показательной способностью для несбалансированных выборок, так как на значение этого показателя весьма сильно влияет большой разброс в количестве примеров одного и другого класса. Подобных минусов лишена другая метрика – прецизионность (precision). Иногда ее тоже называют точностью. Она позволяет рассмотреть долю истинноположительных исходов из всех положительных исходов, т.е. если положительным исходом считать наличие заболевания, данная метрика показывает, например, сколько действительно больных пациентов из всех, классифицированных как больные, было найдено:

$$precision = \frac{\sum TP}{\sum TP + \sum FP}.$$

Полнота или чувствительность (recall, sensitivity) показывает долю истинноположительных примеров среди примеров, являющихся действительно положительными (т.е. определенными как истинноположительные или ложноотрицательные). Если положительный класс – пациенты с наличием заболевания, полнота отражает долю правильно диагностированных пациентов с заболеванием среди всех фактически больных пациентов:

$$recall = \frac{\sum TP}{\sum TP + \sum FN}.$$

F_1 -мера представляет собой гармоническое среднее между прецизионностью и полнотой, и на ее значение в равной степени влияют оба показателя. Хороший классификатор должен обладать одновременно высокими показателями и прецизионности, и полноты, что на практике едва осуществимо, поэтому для удобства рассматривают F_1 -меру. Если хотя бы один из показателей, входящих в формулу F_1 -меры, близок к нулю, F_1 -мера тоже будет близка к нулю. Формула данной метрики имеет вид

$$F_1 = 2 \frac{precision * recall}{precision + recall}.$$

Реализация модели нейронной сети и ее обучения осуществлена на языке Python в Jupiter Notebook с использованием библиотеки машинного обучения Keras версии 2.12.0 на компьютере с процессором Intel Core i5-8300H CPU 2.30GHz и оперативной памятью 6.00 ГБ.

Результаты

Первым был реализован перенос обучения (transfer learning), т.е. использовалась предварительно обученная на наборе данных ImageNet сеть Inception v3. Посредством тонкой настройки к выходу сети были добавлены полносвязные слои для классификации. Слои сети Inception v3 были «заморожены», чтобы не изменять текущие веса сети, обучение проводилось для полносвязных слоев. Модель обучалась в течение 46 эпох. Время обучения – 47 минут на эпоху и около 36 часов на все обучение. Процесс обучения нейронной сети проиллюстрирован графиками (рис. 8). На графиках представлены изменения в процессе обучения точности модели на тренировочном и валидационном наборах и изменения значения функции потерь также на тренировочном и валидационном наборах.




Рис. 8. Графики обучения:
а – графики точности; б – графики потерь

Максимальная достигнутая точность на валидационном наборе – около 60 %, минимальные потери на валидационном наборе – около 0,91. Результаты приемлемы, но было решено провести полное обучение модели с использованием весов, настроенных ранее. Осуществить это позволило применение в течение обучения обратных вызовов, в частности сохранение модели на диске в контрольных точках при изменении определенного параметра (в данном

случае сохранение модели с максимальной точностью на валидационном наборе). Также применялся обратный вызов для ранней остановки обучения (обучение прекращалось, когда потери на валидационном наборе не уменьшались в течение шести эпох). Обратные вызовы в программе были реализованы средствами библиотеки Keras.

Для полного обучения загружалась сохраненная на диске при лучшей точности на валидационном наборе модель, для которой использовался перенос обучения. Были «разморожены» слои предобученной Inception v3, и корректировка весов осуществлялась для всех слоев модели, а не только классифицирующих, как в первом варианте. Процесс полного обучения проиллюстрирован графиками точности и потерь (рис. 9). При полном обучении максимальная достигнутая точность на валидационном наборе выросла до 65 %. Минимальные потери на валидационном наборе снизились с 0,91 до 0,7. Точность и потери на тренировочном наборе приблизились к практически идеальным 95 % точности и значению функции потерь, равному 0,1.




Рис. 9. Графики полного обучения:
а – графики точности; б – графики потерь

Результаты тестирования обученной модели, полученные с помощью библиотеки scikit-learn [40], представлены на рис. 10. Результаты включают таблицу со значениями метрик качества для каждого из пяти классов и средние значения метрик для всех пяти классов, а также матрицы ошибок для каждого класса относительно остальных четырех классов.

Прецизионность для классов 0, 1 и 2, описывающих отсутствие диабетической ретинопатии и две степени развития непролиферативной стадии соответственно, составила 53 % (классы 0 и 1) и 58 % (класс 2). Полнота для этих же классов составила 65 % (класс 0), 45 % (класс 1) и 57 % (класс 2). Соответствующая данным показателям прецизионности и полноты F_1 -мера для классов 0, 1 и 2 составила 0,58, 0,48 и 0,57. Прецизионность для классов 3 и 4 (препролиферативная и пролиферативная стадии) – 75 % и 84 %, полнота – 77 % и 78 %, соответствующая F_1 -мера – 0,76 и 0,81. Среднее значение точности вычислялось с использованием микроусреднения по формуле

$$accuracy_{\text{микро}} = \frac{NTP_0 + NTP_1 + \dots + NTP_4}{NTP_0 + NTP_1 + \dots + NTP + NFP_0 + NFP_1 + \dots + NFP_4},$$

где нижний индекс – номер класса.

	precision	recall	f1-score	support
0	0.53	0.65	0.58	1050
1	0.53	0.45	0.48	1050
2	0.58	0.57	0.57	1050
3	0.75	0.77	0.76	1050
4	0.84	0.78	0.81	1050
accuracy			0.64	5250
macro avg	0.65	0.64	0.64	5250
weighted avg	0.65	0.64	0.64	5250
Label 0	[[681 369] [603 3597]]			
Label 1	[[468 582] [413 3787]]			
Label 2	[[597 453] [437 3763]]			
Label 3	[[804 246] [265 3935]]			
Label 4	[[821 229] [161 4039]]			

Рис. 10. Результаты тестирования

Для остальных метрик вычислялось макроусреднение (macro avg) – среднее значение метрик для разных классов. Вычислялось также взвешенное (нормализованное) макроусреднение (weighted avg), определяемое как сумма произведений метрик разных классов, умноженных на вес каждого класса, равный доле примеров класса в выборке. Взвешенное макроусреднение применяется для несбалансированных классов, но в случае решаемой задачи выборка сбалансированная, поэтому макроусреднение и взвешенное макроусреднение равны.

Для каждого класса (каждой метки класса) показаны матрицы ошибок, построенные по стратегии «один против остальных» (OvR – one vs rest), называемой еще «один против всех» (OvA – one vs all) [36]. В этой стратегии создаются двоичные классификаторы. Первый классификатор производит классификацию объектов на два класса: относящихся к первому классу и ко всем остальным. Второй классификатор – относящихся ко второму классу и всем остальным и т.д.

Видно, что значения метрик для классов 3 и 4 значительно выше, чем значения для классов 0, 1 и 2. Это наблюдение и распределение примеров в матрицах ошибок для каждого класса позволяют интерпретировать полученные результаты тестирования модели.

Обсуждение

Полученные значения прецизионности и полноты позволяют сделать вывод о том, что модель способна различать стадии диабетической ретинопатии в соответствии с общепринятой классификацией ДР с тремя выраженными стадиями (непролиферативная, препролиферативная, пролиферативная). Таким образом, видно, что модель способна с хорошей точностью определить класс 4 (пролиферативная стадия), класс 3 (препролиферативная стадия) и

совокупность классов 2, 1 и 0 (непролиферативная стадия и отсутствие ДР). Предположительно, то небольшое число ложноположительных и ложноотрицательных примеров в матрицах ошибок классов 3 и 4 указывает на небольшую путаницу между этими классами, однако с большой вероятностью эти классы вполне четко отделяются моделью от классов 0, 1 и 2. Небольшие показатели прецизионности для классов 0, 1 и 2 указывают на то, что модель плохо различает изображения классов 1 и 2 (которые представляют собой, по сути, две степени развития одной стадии и содержат крайне схожие изображения) и имеет трудности с поиском различий между снимками без ДР и снимками с ДР на ранней стадии.

Показатели полноты позволяют увидеть, какой процент изображений определенного класса правильно классифицирован. Значения данной метрики для классов 3 и 4 все еще указывают на то, что модель хорошо распознает снимки с препролиферативной и пролиферативной стадиями (полнота в обоих случаях близка к 80 %, т.е. модель распознает правильно практически 80 % изображений каждого из данных классов). Полнота для классов 1 и 2 имеет значения в 45 % и 57 % соответственно, при этом полнота класса 0 равна 65 %, т.е. модель правильно классифицирует 65 % снимков без признаков заболевания, что все-таки можно интерпретировать как проявление способности модели отличать снимки здоровых пациентов, пусть и с немалым числом ошибок, от снимков с ДР на ранней стадии.

Значения полноты (или чувствительности) подтверждают вывод о том, что модель способна различать классы в соответствии с общепринятой классификацией, воспринимая при этом классы 1 и 2 как единый класс, соответствующий непролиферативной стадии, и с некоторыми трудностями отделять снимки без ДР от снимков с ДР на ранней стадии. При этом модель достаточно чувствительна к ДР на поздних стадиях и распознает их с хорошей точностью.

В целом можно увидеть, что модель, которая была обучена на небольшом количестве изображений (15 тыс. изображений из 34 тыс., из-за вычислительных возможностей машины), многие из которых были аугментированы, без использования графического процессора и с одним из самых распространенных и не самым мощным оптимизатором, приобрела способность распознавать стадии прогрессирования диабетической ретинопатии. Причем поздние стадии распознаются данной нейронной сетью очень хорошо, но есть проблемы с поиском признаков заболевания на ранних стадиях.

Дальнейшие исследования будут включать эксперименты с большим количеством обучающих данных, с изображениями различных размеров и качества, с подбором гиперпараметров модели и оптимизаторов. Также возможно рассмотрение других архитектур нейронных сетей.

Заключение

Настоящее исследование посвящено разработке программного обеспечения для диагностики стадии прогрессирования диабетической ретинопатии по снимкам глазного дна. В ходе работы проведена подготовка исходного набора данных с сайта Kaggle, в том числе балансировка набора посредством расширения классов с помощью добавления аугментированных изображений. Реализована модель сверточной нейронной сети на основе архитектуры Inception v3, ее обучение и тестирование. Для реализации использовалась

среда разработки Jupiter Notebook, язык программирования Python и библиотека машинного обучения Keras.

При тестировании программы рассчитывались метрики качества для классификационных моделей. На основе показателей метрик для каждого из классов набора (представляющих определенные стадии заболевания) был сделан вывод о том, что модель научилась распознавать изображения в соответствии с общепринятой классификацией ДР, где развитие заболевания представлено тремя стадиями (непролиферативная, препролиферативная и пролиферативная). Модель, воспринимая два класса из пяти как единую непролиферативную стадию из-за схожести изображений, успешно отличает ее от двух других классов, представляющих препролиферативную и пролиферативную стадию, которые также определяет с хорошими показателями специфичности и чувствительности, однако испытывает затруднения с различием изображений с ДР на ранней стадии и без признаков ДР.

Модель является в России одной из первых моделей, решающих задачу многоклассовой классификации снимков с диабетической ретинопатией, и может быть улучшена и доработана экспериментальным путем для улучшения результатов распознавания и возможности ее использования в профессиональной медицинской деятельности.

Список литературы

1. Kohner E. M. Diabetic retinopathy // British Medical Bulletin. 1989. Vol. 5, № 1. P. 148–173.
2. Диабетическая ретинопатия (тактика ведения пациентов). URL: https://www.rmj.ru/articles/oftalmologiya/Diabeticheskaya_retinopatiya_taktika_vedeniya_pacientov/?ysclid=lfz6iqmxne441287674# (дата обращения: 04.08.2023).
3. Lobo C. L., Bernardes R. C., Cunha-Vaz J. G. Alterations of the Blood–retinal Barrier and Retinal Thickness in Preclinical Retinopathy in Subjects With Type 2 Diabetes // Archives in Ophthalmology. 2000. Vol. 118, № 10. P. 1364–1369. doi: 10.1001/archophth.118.10.1364
4. Демидова Т. Ю., Кожевников А. А. Барометр диабетической ретинопатии: актуальные вопросы и перспективы // Русский медицинский журнал. Медицинское обозрение. 2019. Т. 10, № 3. С. 128–134.
5. Статистика сахарного диабета. URL: <https://rusind.ru/statistika-saxarnogo-diabeta.html> (дата обращения: 04.08.2023).
6. Diagnosing Diabetic Retinopathy with AI. URL: https://about.google/intl/ALL_us/stories/seeingpotential/ (дата обращения: 05.08.2023).
7. Using AI to prevent blindness. URL: <https://health.google/caregivers/arda/> (дата обращения: 05.08.2023).
8. Gulshan V., Peng L., Coram M. [et. al.]. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs // JAMA. 2016. Vol. 316, № 22. P. 2402–2410. doi: 10.1001/jama.2016.17216
9. Sayres R., Taly A., Rahimy E. [et. al.]. Using a Deep Learning Algorithm and Integrated Gradients Explanation to Assist Grading for Diabetic Retinopathy // Ophthalmology. 2019. Vol. 4, № 126. P. 552–564. doi: 10.1016/j.ophtha.2018.11.016
10. Roy P., Tennakoon R., Cao K. [et. al.]. A novel hybrid approach for severity assessment of Diabetic Retinopathy in colour fundus images // 2017 IEEE 14th International Symposium on Biomedical Imaging. 2017. P. 1078–1082.
11. Saeed F., Hussain M., Aboalsamh H. A. Automatic diabetic Retinopathy diagnosis using adaptive fine-tuned convolutional neural network // IEEE Access. 2021. P. 1. doi: 10.1109/ACCESS.2021.3065273
12. ImageNet. URL: <https://www.image-net.org/> (дата обращения: 05.08.2023).

13. Midhula V., Venkatakrishnan S. A Regression-Based Approach to Diabetic Retinopathy Diagnosis Using Efficientnet // *Diagnostics*. 2023. Vol. 13, № 4. P. 774. doi: 10.3390/diagnostics13040774
14. Saeed F., Hussain M., Aboalsamh H. A. [et. al.]. Designing the Architecture of a Convolutional Neural Network Automatically for Diabetic Retinopathy Diagnosis // *Mathematics*. 2023. Vol. 11, № 2. P. 307. doi: 10.3390/math11020307
15. Mercaldo F., Di Giammarco M., Apicella A. [et. al.]. Diabetic retinopathy detection and diagnosis by means of robust and explainable convolutional neural networks // *Neural Computing & Applications*. 2023. Vol. 35. P. 17429–17441. doi: 10.1007/s00521-023-08608-8
16. Abed M. H. A., Muhammed L. A. N., Toman S. H. Diabetic Retinopathy Diagnosis based on Convolutional Neural Network // *Journal of Physics: Conference Series*. 2nd International Virtual Conference on Pure Science (2IVCPS 2021). 2021. Vol. 1999. doi: 10.1088/1742-6596/1999/1/012117
17. Kumar G., Chatterjee S., Chattopadhyay C. DRISTI: a hybrid deep neural network for diabetic retinopathy diagnosis // *Signal, Image and Video Processing*. 2021. Vol. 15. P. 1679–1686. doi: 10.1007/s11760-021-01904-7
18. Mohanty C., Mahapatra S., Acharya B. [et. al.]. Using Deep Learning Architectures for Detection and Classification of Diabetic Retinopathy // *Sensors*. 2023. Vol. 23, № 12. P. 5726. doi: 10.3390/s23125726
19. Лукашевич М. М., Голуб Ю. И. Классификация стадии диабетической ретинопатии на основе нейронных сетей // *Системный анализ и прикладная информатика*. 2022. № 3. С. 12–21. URL: <https://www.elibrary.ru/item.asp?id=49905907> (дата обращения: 05.08.2023).
20. Grzybowski A., Brona P., Gilbert Lim G. [et. al.]. Artificial intelligence for diabetic retinopathy screening: a review // *Eye*. 2020. № 34. P. 451–460. doi: 10.1038/s41433-019-0566-0
21. Uppamma P., Bhattacharya S. Deep Learning and Medical Image Processing Techniques for Diabetic Retinopathy: A Survey of Applications, Challenges, and Future Trends // *Journal of Healthcare Engineering*. 2023. Vol. 2023. doi: 10.1155/2023/2728719
22. Alyoubi W. L., Shalash W. M., Abulkhair M. F. Diabetic retinopathy detection through deep learning techniques: a review // *Informatics in Medicine Unlocked*. 2020. Vol. 20. P. 100377. doi: 10.1016/j.imu.2020.100377
23. 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
24. Мамедов Т. Х., Дзюба Д. В., Наркевич А. Н. Применение сверточных нейронных сетей для распознавания диабетической ретинопатии на цифровых изображениях // *Сибирское медицинское обозрение*. 2022. № 1. С. 83–87. doi: 10.20333/25000136-2022-1-83-87
25. 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
26. Diabetic Retinopathy Unzipped Kaggle. URL: <https://www.kaggle.com/datasets/saipavansaketh/diabetic-retinopathy-unzipped> (дата обращения: 06.08.2023).
27. Augmentor. URL: <https://augmentor.readthedocs.io/en/stable/> (дата обращения: 06.08.2023).
28. tf.keras.preprocessing.image.ImageDataGenerator. URL: https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator#flow_from_dataframe (дата обращения: 06.08.2023).
29. OpenCV-Python Tutorials. URL: https://docs.opencv.org/4.x/d6/d00/tutorial_py_root.html (дата обращения: 06.08.2023).

30. Rethinking the Inception Architecture for Computer Vision. URL: <https://arxiv.org/pdf/1512.00567v3.pdf> (дата обращения: 06.08.2023).
31. Keras: Deep Learning for humans. URL: <https://keras.io/> (дата обращения: 06.06.2023).
32. Шолле Ф. Глубокое обучение на Python. 2-е междунар. изд. СПб. : Питер, 2023. 576 с.
33. Szegedy C., Sergey Ioffe S., Vanhoucke V., Alemi A. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning // Computer Vision and Pattern Recognition. 2016.
34. Keras Applications. URL: <https://keras.io/api/applications/> (дата обращения: 06.08.2023).
35. Inception-Model-Builder-Tensorflow-Keras. URL: <https://github.com/Sakib1263/Inception-InceptionResNet-SEInception-SEInceptionResNet-1D-2D-Tensorflow-Keras> (дата обращения: 07.08.2023).
36. Жерон О. Прикладное машинное обучение с помощью Scikit Learn, Keras и TensorFlow: концепции, инструменты, и техники для создания интеллектуальных систем. СПб. : Диалектика, 2020. 1040 с.
37. Optimizers. URL: <https://keras.io/api/optimizers/> (дата обращения: 07.08.2023).
38. Losses. URL: <https://keras.io/api/losses/> (дата обращения: 07.08.2023).
39. Брюс П., Брюс Э., Гедек П. Практическая статистика для специалистов Data Science. СПб. : БХВ-Петербург, 2021. 352 с.
40. Metrics and scoring: quantifying the quality of predictions. URL: https://scikit-learn.org/stable/modules/model_evaluation.html (дата обращения: 07.08.2023).

References

1. Kohner E.M. Diabetic retinopathy. *British Medical Bulletin*. 1989;5(1):148–173.
2. *Diabeticheskaya retinopatiya (taktika vedeniya patsientov) = Diabetic retinopathy (patient management tactics)*. (In Russ.). Available at: https://www.rmj.ru/articles/oftalmologiya/Diabeticheskaya_retinopatiya_taktika_vedeniya_pacientov/?ysclid=lfz6iqmxne441287674# (accessed 04.08.2023).
3. Lobo C.L., Bernardes R.C., Cunha-Vaz J.G. Alterations of the Blood–retinal Barrier and Retinal Thickness in Preclinical Retinopathy in Subjects With Type 2 Diabetes. *Archives in Ophthalmology*. 2000;118(10):1364–1369. doi: 10.1001/archoph.118.10.1364
4. Demidova T.Yu., Kozhevnikov A.A. Barometer of diabetic retinopathy: actual issues and prospects. *Russkiy meditsinskiy zhurnal. Meditsinskoe obozrenie = Russian Medical Journal. Medical review*. 2019;10(3):128–134. (In Russ.)
5. *Statistika sakharного diabeta = Statistics of diabetes mellitus*. (In Russ.). Available at: <https://rusind.ru/statistika-saxarnogo-diabeta.html> (accessed 04.08.2023).
6. *Diagnosing Diabetic Retinopathy with AI*. Available at: https://about.google/intl/ALL_us/stories/seeingpotential/ (accessed 05.08.2023).
7. *Using AI to prevent blindness*. Available at: <https://health.google/caregivers/arda/> (accessed 05.08.2023).
8. Gulshan V., Peng L., Coram M. et. al. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*. 2016;316(22):2402–2410. doi: 10.1001/jama.2016.17216
9. Sayres R., Taly A., Rahimy E. et. al. Using a Deep Learning Algorithm and Integrated Gradients Explanation to Assist Grading for Diabetic Retinopathy. *Ophthalmology*. 2019;4(126):552–564. doi: 10.1016/j.ophtha.2018.11.016
10. Roy P., Tennakoon R., Cao K. et. al. A novel hybrid approach for severity assessment of Diabetic Retinopathy in colour fundus images. *2017 IEEE 14th International Symposium on Biomedical Imaging*. 2017:1078–1082.
11. Saeed F., Hussain M., Aboalsamh H.A. Automatic diabetic Retinopathy diagnosis using adaptive fine-tuned convolutional neural network. *IEEE Access*. 2021;1. doi: 10.1109/ACCESS.2021.3065273
12. *ImageNet*. Available at: <https://www.image-net.org/> (accessed 05.08.2023).

13. Midhula V., Venkatakrishnan S. A Regression-Based Approach to Diabetic Retinopathy Diagnosis Using Efficientnet. *Diagnostics*. 2023;13(4):774. doi: 10.3390/diagnostics13040774
14. Saeed F., Hussain M., Aboalsamh H. A. et. al. Designing the Architecture of a Convolutional Neural Network Automatically for Diabetic Retinopathy Diagnosis. *Mathematics*. 2023;11(2):307. doi: 10.3390/math11020307
15. Mercaldo F., Di Giammarco M., Apicella A. et. al. Diabetic retinopathy detection and diagnosis by means of robust and explainable convolutional neural networks. *Neural Computing & Applications*. 2023;35:17429–17441. doi: 10.1007/s00521-023-08608-8
16. Abed M.H.A., Muhammed L.A.N., Toman S.H. Diabetic Retinopathy Diagnosis based on Convolutional Neural Network. *Journal of Physics: Conference Series. 2nd International Virtual Conference on Pure Science (2IVCPS 2021)*. 2021;1999. doi: 10.1088/1742-6596/1999/1/012117
17. Kumar G., Chatterjee S., Chattopadhyay C. DRISTI: a hybrid deep neural network for diabetic retinopathy diagnosis. *Signal, Image and Video Processing*. 2021;15:1679–1686. doi: 10.1007/s11760-021-01904-7
18. Mohanty C., Mahapatra S., Acharya B. et. al. Using Deep Learning Architectures for Detection and Classification of Diabetic Retinopathy. *Sensors*. 2023;23(12):5726. doi: 10.3390/s23125726
19. Lukashevich M.M., Golub Yu.I. Classification of the stage of diabetic retinopathy based on neural networks. *Sistemnyy analiz i prikladnaya informatika = System analysis and applied informatics*. 2022;(3):12–21. (In Russ.). Available at: <https://www.elibrary.ru/item.asp?id=49905907> (accessed 05.08.2023).
20. Grzybowski A., Brona P., Gilbert Lim G. et. al. Artificial intelligence for diabetic retinopathy screening: a review. *Eye*. 2020;(34):451–460. doi:10.1038/s41433-019-0566-0
21. Uppamma P., Bhattacharya S. Deep Learning and Medical Image Processing Techniques for Diabetic Retinopathy: A Survey of Applications, Challenges, and Future Trends. *Journal of Healthcare Engineering*. 2023;2023. doi: 10.1155/2023/2728719
22. Alyoubi W.L., Shalash W.M., Abulkhair M.F. Diabetic retinopathy detection through deep learning techniques: a review. *Informatics in Medicine Unlocked*. 2020;20:100377. doi: 10.1016/j.imu.2020.100377
23. 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, and networks in economics, technology, nature, and society*. 2022;(2):90–105. (In Russ.). doi: 10.21685/2227-8486-2022-2-7
24. Mamedov T.Kh., Dzyuba D.V., Narkevich A.N. Application of convolutional neural networks for recognition of diabetic retinopathy on digital images. *Sibirskoe meditsinskoe obozrenie = Siberian Medical Review*. 2022;(1):83–87. (In Russ.). doi: 10.20333/25000136-2022-1-83-87
25. Neroev V.V., Bragin A.A., Zaytseva O.V. Development of a prototype service for diagnosis of diabetic retinopathy based on 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
26. *Diabetic Retinopathy Unziped Kaggle*. Available at: <https://www.kaggle.com/datasets/saipavansaketh/diabetic-retinopathy-unziped> (accessed 06.08.2023).
27. *Augmentor*. Available at: <https://augmentor.readthedocs.io/en/stable/> (accessed 06.08.2023).
28. *tf.keras.preprocessing.image.ImageDataGenerator*. Available at: https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator#flow_from_dataframe (accessed 06.08.2023).
29. *OpenCV-Python Tutorials*. Available at: https://docs.opencv.org/4.x/d6/d00/tutorial_py_root.html (accessed 06.08.2023).
30. *Rethinking the Inception Architecture for Computer Vision*. Available at: <https://arxiv.org/pdf/1512.00567v3.pdf> (accessed 06.08.2023).
31. *Keras: Deep Learning for humans*. Available at: <https://keras.io/> (accessed 06.06.2023).

32. Sholle F. *Glubokoe obuchenie na Python. 2-e mezhdunar. izd. = Deep learning in Python. 2nd inter. ed.* Saint Petersburg: Piter, 2023:576. (In Russ.)
33. Szegedy C., Sergey Ioffe S., Vanhoucke V., Alemi A. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *Computer Vision and Pattern Recognition*. 2016.
34. *Keras Applications*. Available at: <https://keras.io/api/applications/> (accessed 06.08.2023).
35. *Inception-Model-Builder-Tensorflow-Keras*. Available at: <https://github.com/Sakib1263/Inception-InceptionResNet-SEInception-SEInceptionResNet-1D-2D-Tensorflow-Keras> (accessed 07.08.2023).
36. Zheron O. *Prikladnoe mashinnoe obuchenie s pomoshch'yu Scikit Learn, Keras i TensorFlow: kontseptsii, instrumenty, i tekhniki dlya sozdaniya intellektual'nykh system = Applied machine learning using Scikit Learn, Keras and TensorFlow: concepts, tools, and techniques for creating intelligent systems*. Saint Petersburg: Dialektika, 2020:1040. (In Russ.)
37. *Optimizers*. Available at: <https://keras.io/api/optimizers/> (accessed 07.08.2023).
38. *Losses*. Available at: <https://keras.io/api/losses/> (accessed 07.08.2023).
39. Bryus P., Bryus E., Gedek P. *Prakticheskaya statistika dlya spetsialistov Data Science = Practical statistics for Data Science specialists*. Saint Petersburg: BKhV-Peterburg, 2021:352. (In Russ.)
40. *Metrics and scoring: quantifying the quality of predictions*. Available at: https://scikit-learn.org/stable/modules/model_evaluation.html (accessed 07.08.2023).

Информация об авторах / Information about the authors

Дарья Сергеевна Шишикина

магистрант кафедры компьютерных технологий,
Пензенский государственный университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: shishikina.2560@mail.ru

Daria S. Shishikina

Master degree student of the sub-department
of computer technologies,
Penza State University
(40 Krasnaya street, Penza, Russia)

Владимир Иванович Горбаченко

доктор технических наук,
профессор, заведующий кафедрой
компьютерных технологий,
Пензенский государственный университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: gorvi@mail.ru

Vladimir I. Gorbachenko

Doctor of technical sciences, professor,
head of the sub-department of computer
technologies,
Penza State University
(40 Krasnaya street, Penza, Russia)

Михаил Александрович Щербаков

доктор технических наук, профессор,
заведующий кафедрой автоматизации
и телемеханики,
Пензенский государственный университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: mashcherbakov@yandex.ru

Mikhail A. Shcherbakov

Doctor of technical sciences, professor,
head of the sub-department of automation
and telemechanics,
Penza State University
(40 Krasnaya street, Penza, Russia)

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

Поступила в редакцию/Received 06.09.2023

Поступила после рецензирования/Revised 15.10.2023

Принята к публикации/Accepted 17.11.2023