

Применение свёрточных нейронных сетей для анализа изображений глазного дна

Н.Ю. Ильясова^{1,2}, А.С. Широкаев^{1,2}, И.А. Климов²

¹Институт систем обработки изображений РАН - филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

²Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

Аннотация. В настоящей работе предложена технология анализа изображений глазного дна, основанная на применении свёрточной нейронной сети (CNN). Подобрана архитектура CNN, обучение которое производилось на сбалансированной выборке, состоящей из 4 классов изображений: толстые, тонкие сосуды, здоровые участки и область экссудатов. Обучение проводилось на изображениях размерности 12×12, поскольку данная размерность является наиболее оптимальной, как было установлено в ходе экспериментальных исследований. Ошибка тестирования на выборках всех размерностей не превышала 4%. Была проведена сегментация изображения глазного дна с использованием CNN. Ошибка сегментации рассчитана на классе экссудатов, поскольку данный класс является ключевым при проведении операции лазерной коагуляции, и составила 5%. В ходе данной работы был выявлен наиболее информативный канал цветового пространства HSL, с использованием которого удалось уменьшить ошибку сегментации до 3%.

1. Введение

Тяжёлым последствием диабетической ретинопатии (ДРП) является слепота. ДРП затрагивает все отделы сетчатки глаза и приводит к макулярному отёку, который является следствием быстрого снижения зрения [1]. Существует несколько видов лечения данного заболевания, одним из которых является лазерная коагуляция [2]. В результате данного метода наносится серия дозированных микроожогов в зоне отёка на сетчатке. Проведение данной операции осуществляется наложением коагулятов в область, близкую к зоне отека. Создание диагностических систем, позволяющих автоматически определить зону отека, в настоящее время является актуальной задачей [3]. Для автоматизации процедуры лазерной коагуляции [4-5] необходимо провести классификацию объектов на изображении глазного дна [6-8].

Наиболее предпочтительным методом классификации объектов на глазном дне является свёрточная нейронная сеть [9-10]. К такому заключению пришли учёные сообщества по анализу медицинских изображений в ходе проведённых исследований. На международных конференциях и симпозиумах зачастую демонстрируются технологии анализа медицинских данных. В мае 2016 года появился первый специальный выпуск IEEE Transaction on. Первый подробный обзор по применению глубокого обучения для анализа медицинских изображений был опубликован в 2017 году [3]. Сейчас активно наблюдается тенденция развития цифровой медицины.

В работе [11] в качестве модели классификации применялась свёрточная нейронная сеть для диагностики инфекции *H. Pylori infection*. В указанной работе использовалась архитектура, специально подобранная под конкретную задачу. Выводом данной работы является утверждение, что предметную болезнь можно диагностировать на основе эндоскопических изображений с использованием CNN. Работа [12] была посвящена диагностированию гипертонической ретинопатии на ранней стадии. Данная болезнь возникает в сетчатке глаза из-за высокого кровяного давления. Точность классификатора в данной работе составила 98.6%. В статье [13] проводилась разработка инструментальных средств для автоматического анализа изображений биопсии кожи псориаза, которая играет важную роль в клинической помощи. Данная статья представляет собой новаторскую попытку автоматической сегментации изображений биопсии кожи псориаза. Результатом исследования явилась практическая система, разработанная на основе машинного анализа. Продемонстрировано обучение CNN на подготовленном наборе данных для дальнейшего анализа входных изображений.

В данной статье предметом исследований является класс изображений глазного дна с патологическими отклонениями, которые можно наблюдать на различных этапах. Диабетическая ретинопатия является заболеванием, которое характеризуется наличием экссудатов и как следствие утолщением сетчатки (рисунок 1). Изображение глазного с патологией в общем содержит 4 класса объектов: толстые, тонкие сосуды, здоровые участки и экссудаты.




Рисунок 1. Пример диагностического изображения глазного дна без патологий (слева) и с патологией (справа).

2. Обучение свёрточной нейронной сети

Исходные данные анализа содержат 11 обучающих выборок различных размеров. Каждая выборка являлась сбалансированной, при этом общее количество составляет 534 изображений. В данной работе обучение свёрточной нейронной сети производилось на описанных ранее 4 классах изображений глазного дна. Исходная выборка состояла из 75% обучающих изображений и 25% тестовых.

Для предотвращения переобучения сети в процессе обучения также использовалась контрольная выборка. В качестве размера ядра свёртки был выбран размер 3×3 – наиболее оптимальный для изображений 12×12 . Эмпирически была подобрана архитектура CNN, на которой достигалась необходимая точность (не менее 96%). В таблице 1 представлена архитектура эмпирически подобранной свёрточной нейронной сети.

При данной архитектуре была достигнута точность 99,3%, что является наилучшим результатом в распознавании указанных 4 классов изображения. На рисунке 2 продемонстрирован график обучения модели нейронной сети на каждой эпохе обучения.

Для достижения достоверности 95% свёрточную нейронную сеть обучали 120 раз на всех размерах исходных изображений. Рисунок 3 демонстрирует средний результат обучения для каждого размера изображений.

Результаты, показанные на рисунке 3, демонстрируют наибольшую точность классификации при работе с изображениями размером 12×12 .

Таблица 1. Архитектура свёрточной нейронной сети.

N слоя	Слои	Параметры	N слоя	Слои	Параметры
1	Convolutional	300 нейронов	3	Activation	Функция: RELU
1	Activation	Функция: RELU	4	Convolutional	150 нейронов
2	Convolutional	300 нейронов	4	Activation	Функция: RELU
2	Activation	Функция: RELU	4	MaxPooling	Размер 2×2
2	Dropout	0,5	4	Dropout	0.5
2	MaxPooling	Размер 2×2	5	Fully-connected	4
3	Convolutional	150 нейронов	5	Activation	softmax




Рисунок 2. Зависимость точности от размера изображений в обучающей выборке.

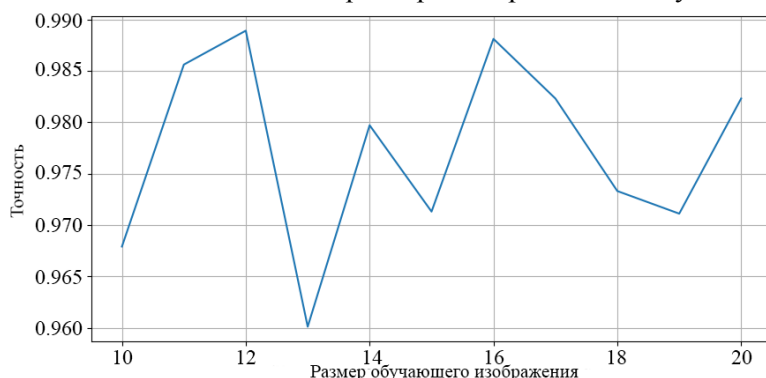


Рисунок 3. Зависимость точности от размера изображений в обучающей выборке.

3. Экспериментальные исследования

Для проведения экспериментов были сформированы выборки, содержащие указанные выше 4 класса изображений размером 12×12, на котором достигается наилучший результат тестирования CNN (рисунок 3). В настоящем исследовании технология глубокого обучения применялась для сегментации изображений глазного дна. На рисунке 4б представлен результат сегментации с использованием CNN. Также была использована оценка врача-эксперта в качестве эталонного изображения (рисунок 4в) для оценки ошибки сегментации. Исследования производились на классе экссудатов, которые были выделены в отдельное изображение (рисунок 4г). Ошибка сегментации указанной области с патологией, проводимой с использованием технологии CNN, вычислялась относительно оценки эксперта. Результат сравнения выделенных зон экссудатов (CNN и эксперта) представлен в таблице 2.




Рисунок 4. Исходное изображение глазного дна (а); результат работы CNN – 4 класса (б); локализация зон экссудатов экспертным способом (в); выделенная область зон экссудатов (г) экспертом, (д) технологией CNN.

На основе указанных в таблице данных была определена ошибка сегментации на классе экссудатов: $E = (k + t) / NM$, где $N \times M$ – размер изображения, k – количество пикселей, которые CNN не распознала, как экссудаты, но они присутствуют на изображении эксперта, t – количество пикселей, которые CNN распознала, как экссудаты, однако они не присутствуют на изображении эксперта, и составила 7%. Ошибка первого рода: $E_1 = l / F$, где l – количество ложно определенных классов-экссудатов, F – общее количество пикселей с экссудатами по изображению эксперта составила 5%.

Таблица 2. Доля зон экссудатов на изображении.

Зоны	Доля зоны экссудатов, %
Зона экссудатов на изображении эксперта	9
Зона экссудатов на изображении CNN	15
Общая зона экссудатов	95.6
Зона экссудатов эксперта, которой нет у CNN	0.4
Зона экссудатов CNN, которой нет у эксперта	6

Ключевую роль при выделении зоны экссудатов играет цветность. Ошибку сегментации можно значительно уменьшить, если работать в определенных цветовых пространствах. В исследованиях [14] установлено, что к цветовосприятию человека ближе всего цветовые модели YUV, RGB и HSL. Однако модели RGB и YUV имеют аппаратные ограничения, с некоторыми типами видеосистем. Для дальнейших исследований была использована модель HSL, т.к. она наилучшим образом отражает цветовые характеристики сосудов и экссудатов. На рисунке 5 показана область патологии, выделенная экспертом в различных цветовых каналах HSL.




Рисунок 5. Область патологии, выделенная экспертом для модели HSL канала (а) H, (б) S, (в) L; область патологии, выделенная CNN для модели HSL канала (г) H, (д) S, (е) L.

Достоверность выделения эксудатов нейронной сетью подтвердили гистограммы изображений, сформированных с использованием CNN и на основе экспертной оценки врача (рисунок 4), совмещенные для сравнения по каждому соответствующему каналу HSL (зеленым цветом выделена гистограмма по изображениям, полученных с помощью эксперта, красным – CNN) (рисунок 6). Гистограммы изображений эксперта определяют интервал значений, где находятся области патологии. На гистограммах видно, что интервал для зоны эксудатов, полученный по результатам свёрточной нейронной сети, меньше интервала, полученного на основе экспертной оценки. Область гистограммы, соответствующая ошибочной классификации с использованием CNN, находится в интервале, выделенном прямоугольными областями (рисунок 6). В таблице 3 представлены значения ошибок сегментации, рассчитанные по каждому каналу цветовой модели HSL. Данные таблицы показали, что самым информативным каналом, имеющим наименьшую ошибку сегментации, является канал H.

Таблица 3. Ошибка сегментации на каждом канале.

Каналы	H	S	L
Ошибка сегментации относительно класса эксудатов, %	3	9	9,8

4. Заключение

В данной работе была применена свёрточная нейронная сеть для анализа изображения глазного дна. Была подобрана архитектура свёрточной нейронной сети, которая обеспечила ошибку тестирования не больше 4%. Размер ядра свёртки был выбран 3×3. CNN обучалась на изображениях размерности 12×12, на которой был достигнут наилучший результат тестирования CNN. В настоящей работе была произведена сегментация входного изображения, при этом свёрточная нейронная сеть с большой точностью смогла определить все классы, на

которых производилось обучение. Ошибка сегментации была рассчитана на классе эксудатов, поскольку данный класс является ключевым при проведении операции лазерной коагуляции. Ошибка сегментации на классе эксудатов составила 7%, ошибка первого рода - 5%.

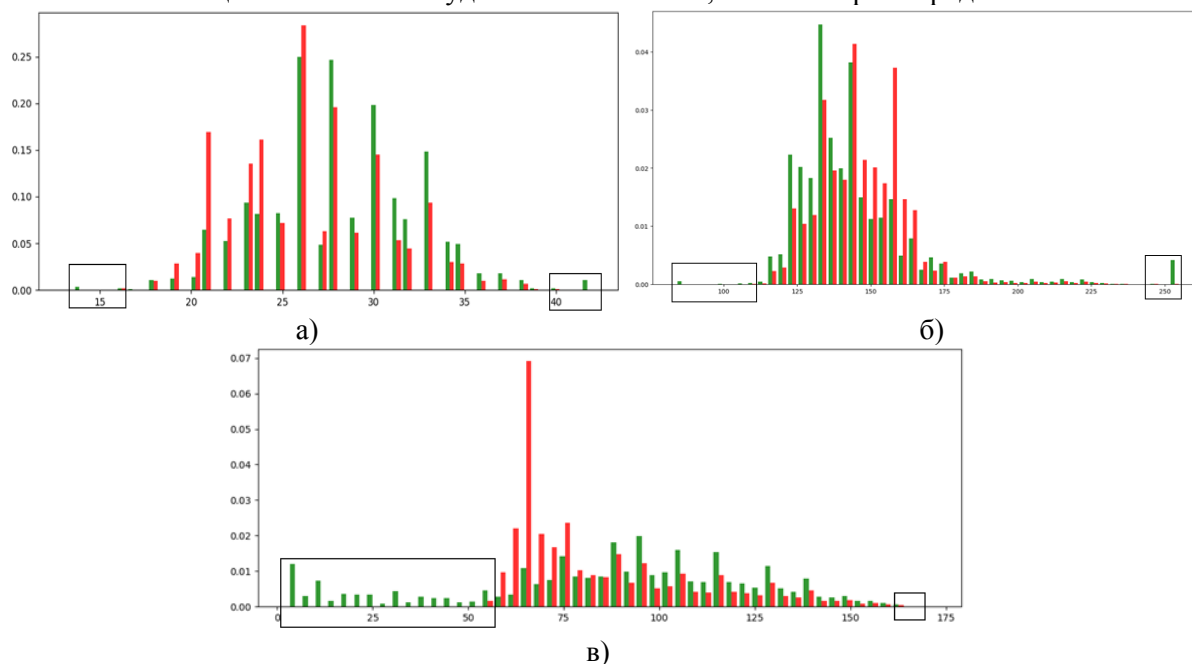


Рисунок 6. Гистограммы изображений, полученных экспертным способом и CNN
а) канал H, б) канал S, в) канал L.

В исследовании была использована модель HSL, поскольку она наилучшим образом отражает цветовые характеристики сосудов и эксудатов. В статье было показано, что самым информативным каналом является канал H, при этом ошибка сегментации составила 3%.

5. Литература

- [1] Шадричев, Ф.Е. Диабетическая ретинопатия // Современная оптометрия. – 2008. – Т. 36, № 4. – С. 8-11.
- [2] Астахов, Ю.С. Современные подходы к лечению диабетического макулярного отека / Ф.Е. Шадричев, М.И. Красавина, Н.Н. Григорьева // Офтальмологические ведомости. – 2009. – №4. – С. 59-69.
- [3] Litjens, G. A survey on deep learning in medical image analysis / G. Litjens, T. Kooi, B.E. Bejnordi // Medical Image Analysis. – 2017. – Vol. 42. – P. 60-88.
- [4] Ilyasova, N. Coagulate map formation algorithms for laser eye treatment / N. Ilyasova, D. Kirsh, R. Paringer, A. Kupriyanov, A. Shirokanev // IEEE Xplore, 2017. – P. 1-5.
- [5] Широқанев, А.С. Исследование алгоритмов расстановки коагулятов на изображение глазного дна / А.С. Широқанев, Д.В. Кириш, Н.Ю. Ильясова, А.В. Куприянов // Компьютерная оптика. – 2018. – Т. 42, № 4. – С. 712-721. DOI: 10.18287/2412-6179-2018-42-4-712-721
- [6] Ilyasova, N.Yu. Intelligent feature selection technique for segmentation of fundus images / N. Ilyasova, R. Paringer, A. Kupriyanov, D. Kirsh // IEEE Xplore. Seventh International Conference on Innovative Computing Technology (INTECH). – 2017. – P. 138-143.
- [7] Ilyasova, N. A smart feature selection technique for object localization in ocular fundus images with the aid of color subspaces / N. Ilyasova, R. Paringer, A. Shirokanev, A. Kupriyanov, N. Ushakova // Procedia Engineering. – 2017. – Vol. 201. – P. 736-745. DOI: 10.1016/j.proeng.2017.09.599.
- [8] Ilyasova, N. Regions of interest in a fundus image selection technique using the discriminative analysis methods / N. Ilyasova, R. Paringer, A. Kupriyanov // Lecture Notes in Artificial

- Intelligence (Subseries of Lecture Notes in Computer Science). – 2016. – Vol. 9972 LNCS. – P. 408-417.
- [9] Мюллер, А. Введение в машинное обучение с помощью Python: руковод. для специалистов по работе с данными / А. Мюллер. – М.: O'Reilly Media, 2017. – 392 с.
- [10] CNNs Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more // Medium [Electronic resource]. – Access mode: https://medium.com/@siddharthdas_32104/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5 (10.08.2017).
- [11] Shichijo, S. Application of Convolutional Neural Networks in the Diagnosis of Helicobacter pylori Infection Based on Endoscopic Images / S. Nomura, K. Aoyama, S. Shichijo // Ebiomedicine [Electronic resource]. – Access mode: [https://www.ebiomedicine.com/article/S2352-3964\(17\)30412-7/fulltext](https://www.ebiomedicine.com/article/S2352-3964(17)30412-7/fulltext) (4.09.2017).
- [12] Raya, J.K.J. The Classification of Hypertensive Retinopathy using Convolutiona Neural Network / J.K.J. Raya, B. K. Triwijoyo, W. Budihartoa, E. Abdurachman // Peer-review under responsibility of the scientific committee of Second International Conference on Computer Science and Computational Intelligence. – Jakarta: Binus University, 2017. – P. 166-173.
- [13] Pal, A. Psoriasis skin biopsy image segmentation using Deep Convolutional Neural Network / A. Pal, U. Garai, A. Chandra // Computer Methods and Programs in Biomedicine. – 2018. – Vol. 159. – P. 59-69.
- [14] Никитаев, В.Г. Экспериментальное исследование цветowych моделей в задачах автоматизированного анализа изображений / В.Г. Никитаев, Е.Ю. Бердникович, В.В. Комаров // Научная сессия МИФИ. – 2004. – Т. 1. – С. 253-254.

Благодарности

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (гранты № 16-41-630761, № 17-01-00972, № 18-37-00418), государственного задания 3.3025.2017/4.6 и Министерства науки и высшего образования Российской Федерации, в рамках выполнения работ по государственному заданию ФНИЦ «Кристаллография и фотоника» РАН (соглашение №007-ГЗ/Ч3363/26).

Convolutional neural network application for analysis of fundus images

N.U. Ilyasova^{1,2}, A.S. Shirokanev^{1,2}, I.A. Klimov¹

¹Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

²Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

Abstract. The article proposes a technology for analyzing fundus images. The technology is based on the convolutional neural network (CNN). The CNN architecture was selected and trained on a sample consisting of 4 image classes: bold, thin vessels, healthy areas, and exudate area. The training was carried out on images of dimension 12×12 , on which the best CNN test result was achieved, amounting to no more than 4%. The fundus image was segmented. The segmentation error was calculated on the class of exudates, since this class is the key when conducting laser coagulation and was 5%. In the course of this work, the most informative channel from the HSL color space was identified, using which it was possible to reduce the segmentation estimate to 3%.