

ПРИМЕНЕНИЕ ГЛУБОКОГО ОБУЧЕНИЯ В ЗАДАЧЕ ДИАГНОСТИРОВАНИЯ ЗАБОЛЕВАНИЙ ПО ИЗОБРАЖЕНИЯМ ОПТИЧЕСКОЙ КОГЕРЕНТНОЙ ТОМОГРАФИИ

Д.В. Цыкунов

tsykunov.d@mail.ru

SPIN-код: 2577-9698

В.А. Моисеева

moiseevavera@inbox.ru

SPIN-код: 6236-6916

МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

Аннотация

В настоящее время технологии искусственного интеллекта играют очень важную роль в развитии многих отраслей науки, в том числе и медицины. В данной работе исследована возможность применения глубоких сверточных нейронных сетей для решения задачи классификации изображений оптической когерентной томографии. В процессе разработки модели использован метод передачи обучения (transfer learning). В результате обучена сверточная нейронная сеть, точность которой на тестовой выборке составляет 99,5 %. Данный результат показывает, что использование глубокого обучения в задачах диагностирования может сыграть большую роль в массовой диагностике пациентов.

Ключевые слова

Оптическая когерентная томография, глубокое обучение, сверточные нейронные сети, искусственный интеллект, классификация изображений, хориоидальная неоваскуляризация, диабетическая ретинопатия, сетчатка глаза

Поступила в редакцию 14.11.2018

© МГТУ им. Н.Э. Баумана, 2018

Введение. На сегодняшний день искусственный интеллект (ИИ) считается одним из самых перспективных направлений во многих областях благодаря быстрому увеличению объемов данных и развитию технологий их обработки. Специалисты ИИ в медицине используют алгоритмы и программное обеспечение для аппроксимации человеческих знаний при анализе сложных медицинских данных. В частности, ИИ может сыграть очень важную роль в диагностировании заболеваний человека путем быстрой классификации большого количества изображений.

Обработка медицинских изображений и постановка диагноза требует соответствующих знаний от специалиста, классифицирующего эти изображения. С учетом этого факта проведение массовой диспансеризации населения требует большого количества высококвалифицированных работников, что в свою очередь является сложной задачей с точки зрения поиска самих специалистов и выделения бюджета на их трудоустройство.

Традиционный алгоритмический подход для классификации изображений основывался на их сегментации, а затем идентификации каждого сегментируемого объекта с помощью статистических или неглубоких нейронных машинно-

обучающихся классификаторов [1]. Создание, проверка и доработка каждого классификатора занимали длительное время и требовали участия квалифицированных специалистов, а также больших денежных затрат [2, 3].

Применение алгоритмов ИИ для обучения глубоких сверточных нейронных сетей может сделать возможным создание программного обеспечения для постановки диагноза и проведения массовой диспансеризации в тех регионах, где нет специалистов необходимого профиля.

В данной статье исследовано применение заранее обученных сверточных нейронных сетей для диагностирования заболеваний сетчатки человеческого глаза посредством классификации изображений оптической когерентной томографии.

Метод. Сверточная нейронная сеть — сеть, состоящая из слоев свертки (*convolution layer*). Обычно в сверточную нейронную сеть включают слои субдискретизации (*pooling layer*) и полносвязный слой (*fully connected layer*) [4]. Одной из первых широко известных сверточных нейронных сетей является сеть LeNet-5 Яна ЛеКуна [5] (рис. 1), архитектура которой стала основой для всех современных сверточных нейронных сетей.

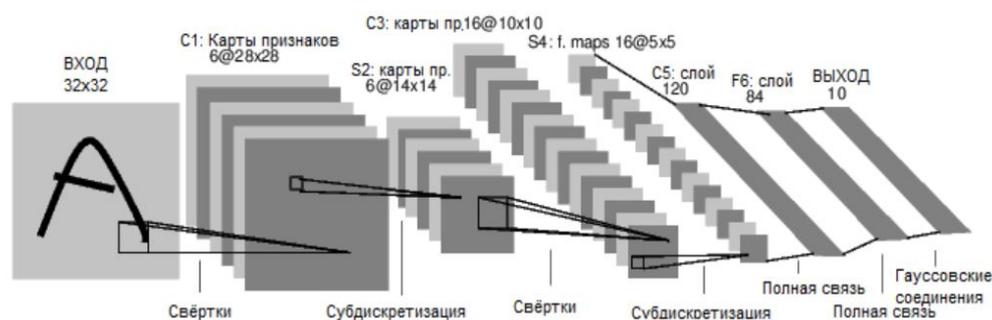


Рис. 1. LeNet-5 [4]

Развитие сверточных нейронных сетей позволило добиться значительных успехов в задачах классификации [6] и распознавания образов [5] на изображениях.

Одна из проблем использования сверточных нейронных сетей заключается в том, что для обучения сети «с нуля» необходимо иметь очень большую тренировочную выборку. Поскольку обычно медицинские изображения, характеризующие конкретные заболевания, в базах данных имеются лишь в небольшом количестве, приходится искать другие способы обучения.

Таким способом является метод передачи обучения (*transfer learning*) [7] (рис. 2), который заключается в том, чтобы не учить нейронную сеть «с нуля», а использовать заранее натренированную на большом объеме данных сеть. Такой метод оказывается высокоэффективным, особенно когда речь идет о небольшом объеме размеченных данных.

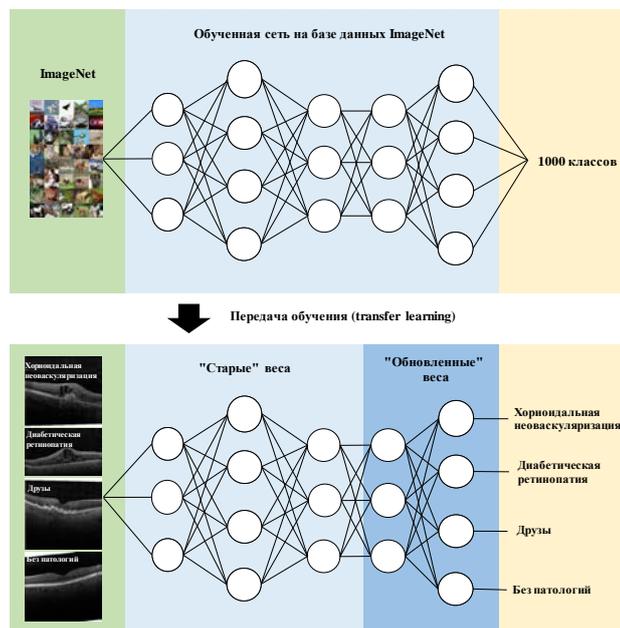


Рис. 2. Метод передачи обучения [8]

Данные. В работе использовали 84 470 размеченных изображений оптической когерентной томографии взрослых пациентов [9]. Каждое изображение проходило многоуровневую систему классификации. Все изображения разделены на четыре класса: 1) хориоидальная неоваскуляризация, 2) диабетическая ретинопатия, 3) друзы, 4) без патологий (рис. 3).

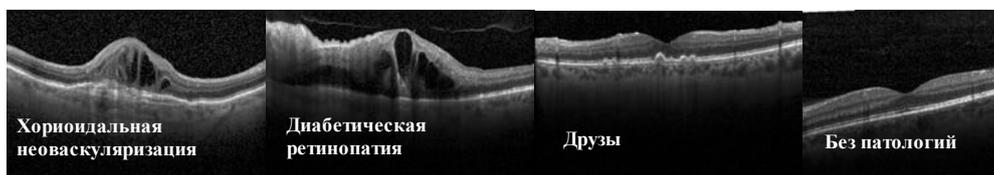


Рис. 3. Примеры изображений из набора данных

В качестве обучающей выборки был использован набор данных, состоящий из 83 433 изображений (37 181 — хориоидальная неоваскуляризация, 11 342 — диабетическая ретинопатия, 8 600 — друзы, 26 310 — без патологий). Размеры тестовой и валидационной выборок составляли соответственно 1 000 (по 250 на каждый класс) и 32 (по 8 на каждый класс) изображения. Валидационная выборка понадобится для выбора наилучшей конфигурации модели. Тестовая выборка в дальнейшем, после всего процесса обучения, будет использоваться для создания матрицы несоответствий, которая покажет насколько хорошо наша модель классифицирует изображения.

При формировании обучающей выборки произведены случайные трансформации изображений: изменение их размеров до 224×224 пикселя, произвольный горизонтальный поворот изображения с вероятностью $p = 0,5$. Также

все изображения из тестовой и валидационной выборок обрезаны по центру до размера 224×224 пикселя.

Обучение модели. В данной работе использовали модель VGG16 [10] заранее обученную на более чем 14 000 000 изображений, принадлежащих 1 000 классам, из базы данных ImageNet. Архитектура данной сети представлена на рис. 4.

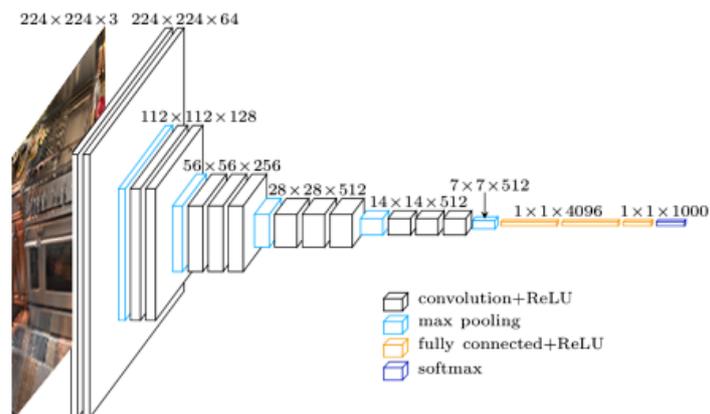


Рис. 4. Архитектура сети VGG16:

Convolution+ReLU — слой свертки; Max pooling — слой субдискретизации;
Fully connected + ReLU — полносвязный слой; Softmax — функция активации

В процессе обучения обновлялись веса только полносвязных слоев сети. Обучение происходило в две эпохи. График убывания кросс-энтропийной ошибки представлен на рис. 5.

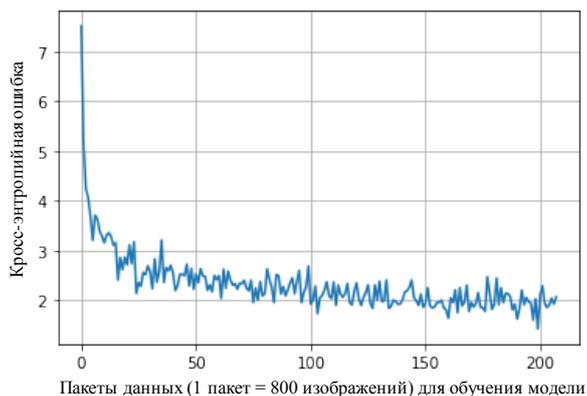


Рис. 5. Убывание функции ошибки

В конце каждой эпохи мы проверяем достоверность нашей модели с помощью валидационной выборки и сохраняем ее конфигурацию, если точность оказалась выше, чем на последней, самой удачной (т. е. самой точной) конфигурации.

Результаты. По матрице несоответствий, представленной на рис. 6, видно, что точность модели на тестовой выборке составляет 99,5 %. Также на этом рисунке можно увидеть, сколько раз модель дала ложное и истинное предсказание для конкретного заболевания. Значения, расположенные по диагонали матрицы, показывают, сколько раз модель дала истинное предсказание для конкретного заболевания.

Работа сети на случайных изображениях из тестовой выборки показана на рис. 7.

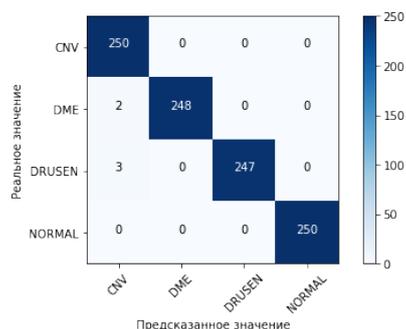
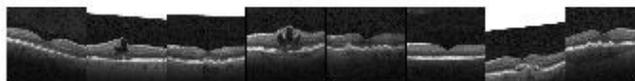


Рис. 6. Матрица несоответствий:

CNV — хориоидальная неоваскуляризация; DME — диабетическая ретинопатия; DRUSEN — друзы; NORMAL — без патологий

Реальное значение:

['NORMAL', 'DME', 'DRUSEN', 'DME', 'DRUSEN', 'NORMAL', 'CNV', 'DRUSEN']



Предсказанное значение:

['NORMAL', 'DME', 'DRUSEN', 'DME', 'CNV', 'NORMAL', 'CNV', 'DRUSEN']

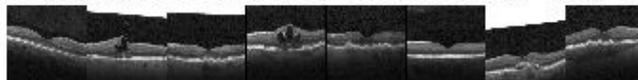


Рис. 7. Пример классификации

Вывод. Разработана модель для классификации изображений оптической когерентной томографии. Точность модели на тестовой выборке составила 99,5 %.

Данная модель может быть использована для создания программного комплекса в целях автоматизации процесса диагностирования пациентов, что делает возможным проведение обследования в тех регионах, где нет специалистов-офтальмологов. Также с помощью этого комплекса можно осуществить массовое диагностирование пациентов, сбор данных и их последующий анализ для формирования статистики об офтальмологических заболеваниях.

Литература

- [1] Goldbaum M., Moezzi S., Taylor A., Chatterjee S., Boyd J., Hunter E., Jain R. Automated diagnosis and image understanding with object extraction, object classification, and inferencing in retinal images. *Proc. 3rd IEEE Int. Conf. Imaging*, 1996, vol. 3, pp. 695–698.
- [2] Hoover A., Goldbaum M. Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels. *IEEE Trans. Med. Imaging*, 2003, vol. 22, no. 8, pp. 951–958.

-
- [3] Hoover A., Kouznetsova V., Goldbaum M. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. *IEEE Trans. Med. Imaging*, 2000, vol. 19, no. 1, pp. 203–210.
 - [4] Сикорский О.С. Обзор свёрточных нейронных сетей для задачи классификации изображений. *Новые информационные технологии в автоматизированных системах*, 2017, № 20, с. 37–42.
 - [5] LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient-based learning applied to document recognition. *Proc. IEEE*, 1998, vol. 86, no. 11, pp. 2278–2324
 - [6] Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., Huang Z., Karpathy A., Khosla A., Bernstein M., Berg A.C., Fei-Fei L. Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 2015, vol. 115, no. 3, pp. 211–252.
 - [7] Shie Ch.K., Chuang Ch.H., Chou Ch.N., Wu M.H., Chang E.Y. Transfer representation learning for medical image analysis. *37th Annual Int. Conf. IEEE EMBC*, 2015, pp. 711–714.
 - [8] Kermany D.S., Goldbaum M., Cai W., et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 2018, vol. 172, no. 5, pp. 1122–1131-e9.
 - [9] Kermany D., Zhang K., Goldbaum M. Labeled optical coherence tomography (OCT) and chest X-Ray images for classification. Version 2.
URL: <https://data.mendeley.com/datasets/rsbjbr9sj/2> (дата обращения: 28.08.2018).
 - [10] Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. URL: <https://arxiv.org/abs/1409.1556> (дата обращения: 28.08.2018).

Цыкунов Дмитрий Владимирович — студент кафедры «Биомедицинские технические системы», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

Моисеева Вера Андреевна — студентка кафедры «Биомедицинские технические системы», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

USING OF DEEP LEARNING IN THE TASK OF DIAGNOSING DISEASES USING OPTICAL COHERENCE TOMOGRAPHY IMAGES

D.V. Tsykunov

tsykunov.d@mail.ru

SPIN-code: 2577-9698

V.A. Moiseeva

moiseevavera@inbox.ru

SPIN-code: 6236-6916

Bauman Moscow State Technical University, Moscow, Russian Federation

Abstract

Nowadays artificial intelligence technologies play a very important role in the development of many fields of science, including medicine. In this article considers the possibility of using deep convolutional neural networks to solve the problem of image classification of optical coherent tomography. In the process of developing a model, a method of transfer learning was used. As a result, a convolutional neural network was trained, the accuracy of which in the test sample is 99.5%. This result shows that using of deep learning in the tasks of diagnosis can play a large role in the mass diagnosis of patients.

Keywords

Optical coherent tomography, deep learning, convolutional neural networks, artificial intelligence, image classification, choroidal neovascularization, diabetic retinopathy, retina

Received 14.11.2018

© Bauman Moscow State Technical University, 2018

References

- [1] Goldbaum M., Moezzi S., Taylor A., Chatterjee S., Boyd J., Hunter E., Jain R. Automated diagnosis and image understanding with object extraction, object classification, and referencing in retinal images. *Proc. 3rd IEEE Int. Conf. Imaging*, 1996, vol. 3, pp. 695–698.
- [2] Hoover A., Goldbaum M. Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels. *IEEE Trans. Med. Imaging*, 2003, vol. 22, no. 8, pp. 951–958.
- [3] Hoover A., Kouznetsova V., Goldbaum M. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. *IEEE Trans. Med. Imaging*, 2000, vol. 19, no. 1, pp. 203–210.
- [4] Sikorskiy O.S. Review on grid neuron networks for image classification problem. *Novye informatsionnye tekhnologii v avtomatizirovannykh sistemakh*, 2017, no. 20, pp. 37–42.
- [5] LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient-based learning applied to document recognition. *Proc. IEEE*, 1998, vol. 86, no. 11, pp. 2278–2324
- [6] Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., Huang Z., Karpathy A., Khosla A., Bernstein M., Berg A.C., Fei-Feiand L. Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 2015, vol. 115, no. 3, pp. 211–252.
- [7] Shie Ch.K., Chuang Ch.H., Chou Ch.N., Wu M.H., Chang E.Y. Transfer representation learning for medical image analysis. *37th Annual Int. Conf. IEEE EMBC*, 2015, pp. 711–714.
- [8] Kermany D.S., Goldbaum M., Cai W., et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 2018, vol. 172, no. 5, pp. 1122–1131-e9.

- [9] Kermany D., Zhang K., Goldbaum M. Labeled optical coherence tomography (OCT) and chest X-Ray images for classification. Version 2. Available at: <https://data.mendeley.com/datasets/rscbjbr9sj/2> (accessed: 28 August 2018).
- [10] Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. Available at: <https://arxiv.org/abs/1409.1556> (accessed: 28 August 2018).

Tsykunov D.V. — student, Department of Biomedical Engineering systems, Bauman Moscow State Technical University, Moscow, Russian Federation.

Moiseeva V.A. — student, Department of Biomedical Engineering systems, Bauman Moscow State Technical University, Moscow, Russian Federation.