

УДК 004.032.2

DOI: 10.18413/2518-1092-2020-5-1-0-3

Выгоняйло В.Р.<sup>1</sup>  
Михелев В.М.<sup>2</sup>**ПОВЫШЕНИЕ ТОЧНОСТИ КЛАССИФИКАЦИИ  
РЕНТГЕНОВСКИХ СНИМКОВ С ИСПОЛЬЗОВАНИЕМ  
ДООБУЧЕНИЯ СОСТАВНОЙ НЕЙРОСЕТИ**<sup>1</sup>) Белгородский государственный национальный исследовательский университет,  
ул. Победы, д. 85, г. Белгород, 308015, Россия<sup>2</sup>) Белгородский государственный технологический университет им. В.Г. Шухова, ул. Костюкова, д. 46,  
г. Белгород, 308012, Россия*e-mail: 1078978@bsu.edu.ru, vm-mikhelev@ya.ru***Аннотация**

Данная статья посвящена решению задачи классификации рентгеновских снимков грудной клетки при помощи приема дообучения предобученной сверточной нейронной сети, обученной на малых наборах данных. Используется обучаемый бинарный классификатор для выявления наличия или отсутствия патологии нижних дыхательных путей. В работе приведены результаты вычислительного эксперимента и показано улучшение точности при решении задачи классификации. Исследование направлено на выявление качественного улучшения показателя точности при применении составной нейронной сети.

**Ключевые слова:** классификация изображений, рентгеновские снимки грудной клетки, составные нейронные сети, нейронные сети, сверточные нейронные сети, keras, tensorflow.

UDC 004.032.2

Vygoniailo V.R.<sup>1</sup>  
Mikhelev V.M.<sup>2</sup>**INCREASING ACCURACY CLASSIFICATION OF X-RAY IMAGES  
USING TRAINING OF COMPOSITE NEURAL NETWORK**<sup>1</sup>) Belgorod State National Research University, 85 Pobedy St., Belgorod, 308015, Russia<sup>2</sup>) Belgorod State Technological University named after V.G. Shukhov, 46 Kostyukova St., Belgorod,  
308012, Russia*e-mail: 1078978@bsu.edu.ru, vm-mikhelev@ya.ru***Abstract**

This article is devoted to solving the problem of classifying chest x-ray images by using the retraining of a pre-trained convolutional neural network trained on small data sets. A trained binary classifier is used to detect the presence or absence of lower respiratory tract pathology. The paper presents the results of a computational experiment and shows an improvement in accuracy in solving the classification problem. The study aims to identify a qualitative improvement in the accuracy index when using a composite neural network.

**Keywords:** image classification, chest x-rays, composite neural networks, neural networks, convolutional neural networks, keras, tensorflow.

**ВВЕДЕНИЕ**

Туберкулез — это инфекционное заболевание, вызываемое бактерией *Mycobacterium tuberculosis*. Туберкулез является основной причиной смерти от инфекционных заболеваний во всем мире, наряду с синдромом приобретенного вируса иммунодефицита человека (известным как ВИЧ). В 2014 году примерно 9600000 человек заболели туберкулезом, что привело к 1500000 смертей [1].

Хотя следует избегать неизбирательного массового скрининга на туберкулез, Всемирная Организация Здравоохранения рекомендует более широко использовать скрининг с помощью рентгенографии грудной клетки и быстрой молекулярной диагностики для отдельных групп высокого риска [1]. Рентгенография грудной клетки является важной частью многих алгоритмов скрининга на туберкулез во всем мире [1-2]. Кроме того, визуализация также играет важную роль в обследовании пациентов с подозрением на туберкулез легких [2-3].

Известно [4-5], что во многих местах с преобладанием туберкулеза наблюдается относительный недостаток опыта в интерпретации результатов рентгенографии, что может отрицательно сказаться на эффективности скрининга и обследования. Эффективный автоматизированный и экономически эффективный метод может помочь улучшить результаты обследований в развивающихся странах и облегчить раннее выявление заболеваний. Однако исследование не всегда располагает большим набором входных данных или большим объемом вычислительных мощностей [4, 7].

## **ОСНОВНАЯ ЧАСТЬ**

### **Описание датасета**

Датасет Pulmonary Chest X-Ray Abnormalities содержит рентгеновские снимки грудной клетки человека в формате изображения \*.png, имеет обучающую и тестовую выборки. Этот набор данных содержит более 500 рентгеновских снимков с клиническими метками, собранными рентгенологами.

Перед началом вычислительного эксперимента необходимо подготовить входной набор данных:

1. Создать общий каталог, который будет подаваться, как входные данные.
2. В общем каталоге разместить еще два: каталог данных для обучения и каталог данных для проверки.
3. В каталогах для обучения и проверки разделить медицинские снимки еще на два каталога: с патологией и без.
4. Привести каждое изображение к размеру 299 x 299 px.

### **Составная нейронная сеть на основе Inception V3**

Существует несколько моделей сверточных нейронных сетей для классификации изображений: LeNet, AlexNet, VGG, Inception и ResNet. Из вышеперечисленных только две архитектуры отличаются наличием глубоких слоев: Inception (22 слоя) и ResNet (152 слоя), что, несомненно, влияет на стоимость вычислений. Несмотря на то, что Inception (рис. 1) имеет меньше слоев, чем ResNet, в ней имеются параллельные сверточные слои с фильтрами различного размера (например, 1x1, 3x3, 5x5). Также, использование обратной связи по ошибкам в нескольких точках сети дает оптимальные количественные и качественные показатели точности и скорости вычисления для вычислительного эксперимента в данном исследовании.

Для создания составной сети необходимо подключить все необходимые модули из keras в составе tensorflow. Далее задается размер входных изображений (299), потому что именно на изображениях такого размера обучена модель inception v3. Устанавливается размер мини выборки – 32.

Загружаем данные из ранее подготовленной директории. Так как данных в данном датасете не очень много, то используем дополнение данных с помощью генераторов keras: каждый пиксель изображения будет разделен на 255, изображения будут поворачиваться на угол до 10 градусов, будут выполняться сдвиги по осям до 10% и размер изображения будет изменяться в пределах 10% (рис. 2).




Рис. 1. Иллюстрация архитектуры сети Inception  
Fig. 1. Illustration of Inception Network Architecture




Рис. 2. Изображения, созданные генератором keras:

а – изображение повернуто вправо, б – изображение повернуто вправо и сдвинуто вверх, в – изображение сдвинуто влево, г – изменен размер изображения, д – изображение сдвинуто вправо, е – изображение сдвинуто вниз

Fig. 2. Images created by keras generator:

a – the image is rotated to the right, b – the image is rotated to the right and shifted up, c - the image is shifted to the left, d – the image is resized, e – the image is shifted to the right, e – the image is shifted down

Далее загружаем предварительно обученную сеть Inception и “замораживаем” веса предварительно обученной сети.

Создаем составную нейронную сеть на основе загруженной, добавляем к сети новый классификатор: добавляем слой GlobalAveragePooling2D, один полносвязный слой с 512

нейронами, выбираем полулинейную активацию и используем пакетную нормализацию, слой dropout с показателем 0,5 и выходной слой с одним нейроном и функцией активации sigmoid.

Sigmoid изменяется от 0 до 1 и хорошо подходит для бинарной классификации.

В результате получаем составную модель, которая в начальной части содержит слои inception, а в конце – добавленный полносвязный слой.

Компилируем модель, в качестве функции ошибки используем бинарную перекрёстную энтропию, оптимизатор RMSprop, так как используем предварительно обученную модель, то используем низкий параметр скорости обучения ( $1e-4$ ) и метрику качества обучения – accuracy (доля правильных ответов).

Сохраняем модель, только если доля правильных ответов на проверочном наборе данных лучше, чем на предыдущих этапах. Уменьшаем параметр скорости обучения, если в течение 3 эпох не изменяется доля правильных ответов на проверочном наборе данных.

### ВЫЧИСЛИТЕЛЬНЫЙ ЭКСПЕРИМЕНТ

Обучаем нейронную сеть с помощью метода fit\_generator в течение 20 эпох (рис. 3).

```
4/4 [.....] - 1s 238ms/step - loss: 0.5237 - acc: 0.8500
Epoch 00017: val_acc improved from 0.76667 to 0.85000, saving model to inceptionv3
- 18s - loss: 0.0531 - acc: 0.9794 - val_loss: 0.5337 - val_acc: 0.8300
Epoch 18/20
4/4 [.....] - 1s 211ms/step - loss: 0.5649 - acc: 0.8583
Epoch 00018: val_acc improved from 0.85000 to 0.85833, saving model to inceptionv3
- 18s - loss: 0.0160 - acc: 0.9956 - val_loss: 0.5649 - val_acc: 0.8383
Epoch 19/20
4/4 [.....] - 1s 212ms/step - loss: 0.5229 - acc: 0.8833
Epoch 00019: val_acc improved from 0.85833 to 0.88333, saving model to inceptionv3
- 17s - loss: 0.0166 - acc: 0.9956 - val_loss: 0.5329 - val_acc: 0.8333
Epoch 20/20
4/4 [.....] - 1s 210ms/step - loss: 0.5804 - acc: 0.8833
Epoch 00020: val_acc did not improve from 0.88333
- 16s - loss: 0.0317 - acc: 0.9897 - val_loss: 0.5804 - val_acc: 0.8333
```

Рис. 3. Результат по завершению обучения, доля правильных ответов на проверочном наборе данных 0.8833

Fig. 3. The result of the completion of training, the proportion of correct answers on the test data set 0.8833

Для улучшения точности “размораживаем” два последних блока Inception и дообучаем модель на новом наборе данных.

Загружаем лучшие веса, которые были получены в ходе обучения, “размораживаем” слои Inception, начиная от слоя 249 и далее компилируем сеть с теми же параметрами. Запускаем процесс дообучения еще на 5 эпох (рис. 4).

```
Epoch 00001: val_acc improved from -inf to 0.90000, saving model to inceptionv3_fine
- 19s - loss: 0.0770 - acc: 0.9002 - val_loss: 0.5210 - val_acc: 0.9000
Epoch 2/5
4/4 [*****] - 1s 207ms/step - loss: 0.5466 - acc: 0.8917

Epoch 00002: val_acc did not improve from 0.90000
- 10s - loss: 0.0154 - acc: 0.9971 - val_loss: 0.5466 - val_acc: 0.8917
Epoch 3/5
4/4 [*****] - 1s 234ms/step - loss: 0.5259 - acc: 0.8833

Epoch 00003: val_acc did not improve from 0.90000
- 14s - loss: 0.1290 - acc: 0.9809 - val_loss: 0.5259 - val_acc: 0.8833
Epoch 4/5
4/4 [*****] - 1s 204ms/step - loss: 0.5758 - acc: 0.8833

Epoch 00004: val_acc did not improve from 0.90000

Epoch 00004: ReduceLROnPlateau reducing learning rate to 4.999999873689376e-05.
- 19s - loss: 0.0163 - acc: 0.9941 - val_loss: 0.5758 - val_acc: 0.8833
Epoch 5/5
4/4 [*****] - 1s 213ms/step - loss: 0.6435 - acc: 0.8750

Epoch 00005: val_acc did not improve from 0.90000
- 11s - loss: 0.0174 - acc: 0.9920 - val_loss: 0.6435 - val_acc: 0.8750
```

Рис. 4. Результат по завершению обучения, доля правильных ответов на проверочном наборе данных 0.9000

Fig. 4. The result of the completion of training, the proportion of correct answers on the test data set 0.9000

Лучшая доля правильных ответов получилась уже на первой же эпохе (0.9). Далее доля правильных ответов начала падать, а на обучающем наборе данных увеличиваться, это означает, что началось переобучение. Сравнение значений результатов обучения приведены в таблице.

Таблица

**Доля правильных ответов на проверочном наборе**

Table

**The proportion of correct answers on the test set**

обучение		дообучение	
эпоха	доля правильных ответов	эпоха	доля правильных ответов
17	0.8500	1	0.9000
18	0.8583	2	0.8917
19	0.8833	3	0.8833
20	0.8833	4	0.8750

Из таблицы видно, что при дообучении доля правильных ответов повысилась на первой эпохе, а затем начала падать, это означает что наступило избыточное обучение.

Важно отметить, что временные затраты на обучения зависят от аппаратного обеспечения. Параметры стенда: NVIDIA gforce 940m + Intel Core i5 6300 □Q + 16GB RAM.

Также для использования tensorflow-gpu необходимо установить следующее программное обеспечение:

- NVIDIA GPU drivers —CUDA 10;
- CUDA Toolkit;
- CUPTI;
- cuDNN SDK (>= 7.4.1).

### ЗАКЛЮЧЕНИЕ

В ходе вычислительного эксперимента было выявлено, что дообучения составной нейронной сети, может повысить точность обученной ранее обученной модели. Однако стоит отметить, что данный способ стоит использовать только при малом количестве входных данных или же при отсутствии больших вычислительных мощностей, которые будут не в состоянии обработать большой объем данных или за приемлемое время.

Если же имеются достаточные входные данные и вычислительные мощности, то следует обучать новую модель. Предварительное обучение по тангенциально связанным наборам данных, таким как ImageNet, помогает в ситуациях, когда данные обучения ограничены, но может привести к непреднамеренным искажениям, которые нежелательны в клинических условиях.

*Работа выполнена при поддержке гранта РФФИ 19-07-00133А «Разработка интеллектуальных высокопроизводительных методов распознавания медицинских изображений и создание компьютерной системы поддержки принятия решений в виде облачного сервиса для прогнозирования и диагностики в персональной медицине».*

### Список литературы

1. World Health Organization. Global tuberculosis report 2015 [Electronic resource]. Access mode: [http://apps.who.int/iris/bitstream/10665/191102/1/9789241565059\\_eng.pdf](http://apps.who.int/iris/bitstream/10665/191102/1/9789241565059_eng.pdf)
2. World Health Organization. Systematic screening for active tuberculosis: Principles and recommendations [Electronic resource]. Access mode: [http://www.who.int/tb/publications/Final\\_TB\\_Screening\\_guidelines.pdf](http://www.who.int/tb/publications/Final_TB_Screening_guidelines.pdf)
3. Chest tuberculosis: Radiological review and imaging recommendations. / Bhalla A.S [et al.] // Indian J Radiol Imaging – 2015. – №25(3). – P. 213-225.
4. An automated tuberculosis screening strategy combining X-ray-based computer-aided detection and clinical information. / Melendez J, [et al.] // Sci Rep – 2016. – №6.
5. High sensitivity of chest radiograph reading by clinical officers in a tuberculosis prevalence survey. / Hoog A. [et al.] // Int J Tuberc Lung Dis – 2011. – №15(10). – P. 1308-1314.
6. Antani S. Automated Detection of Lung Diseases in Chest X-Rays. A Report to the Board of Scientific Counselors. US National Library of Medicine [Electronic resource]. Access mode: <https://lhncbc.nlm.nih.gov/system/files/pub9126.pdf>
7. Jaeger S. Automatic screening for tuberculosis in chest radiographs: a survey. / Jaeger S., Karargyris A., Candemir S. // Quant Imaging Med Surg – 2013. – №3(2). P. 89-99.

### References

1. World Health Organization. Global tuberculosis report 2015 [Electronic resource]. Access mode: [http://apps.who.int/iris/bitstream/10665/191102/1/9789241565059\\_eng.pdf](http://apps.who.int/iris/bitstream/10665/191102/1/9789241565059_eng.pdf)
2. World Health Organization. Systematic screening for active tuberculosis: Principles and recommendations [Electronic resource]. Access mode: [http://www.who.int/tb/publications/Final\\_TB\\_Screening\\_guidelines.pdf](http://www.who.int/tb/publications/Final_TB_Screening_guidelines.pdf)
3. Chest tuberculosis: Radiological review and imaging recommendations. / Bhalla A.S [et al.] // Indian J Radiol Imaging – 2015. - №25(3). – P. 213-225.
4. An automated tuberculosis screening strategy combining X-ray-based computer-aided detection and clinical information. / Melendez J, [et al.] // Sci Rep – 2016. – №6.
5. High sensitivity of chest radiograph reading by clinical officers in a tuberculosis prevalence survey. / Hoog A. [et al.] // Int J Tuberc Lung Dis – 2011. – №15(10). – P. 1308–1314.
6. Antani S. Automated Detection of Lung Diseases in Chest X-Rays. A Report to the Board of Scientific Counselors. US National Library of Medicine [Electronic resource]. Access mode: <https://lhncbc.nlm.nih.gov/system/files/pub9126.pdf>
7. Jaeger S. Automatic screening for tuberculosis in chest radiographs: a survey. / Jaeger S., Karargyris A., Candemir S. // Quant Imaging Med Surg – 2013. – №3(2). P. 89-99.

**Выгоняйло Виктор Романович**, магистрант кафедры математического и программного обеспечения информационных систем, НИУ «БелГУ»

**Михелев Владимир Михайлович**, кандидат технических наук, доцент, доцент кафедры программного обеспечения вычислительной техники и автоматизированных систем, БГТУ им. В.Г. Шухова

**Vygoniailo Victor Romanovich**, master student, Department of Mathematical and Software Information Systems, Belgorod State National Research University

**Mikhelev Vladimir Mikhailovich**, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Computer Software and Automated Systems, Belgorod State Technological University named after V.G. Shukhov