

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ  
РОССИЙСКОЙ ФЕДЕРАЦИИ  
ТОМСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ

**МАТЕРИАЛЫ**  
**IX-й Международной научной конференции**  
**«МАТЕМАТИЧЕСКОЕ**  
**И ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ**  
**ИНФОРМАЦИОННЫХ,**  
**ТЕХНИЧЕСКИХ**  
**И ЭКОНОМИЧЕСКИХ СИСТЕМ»**

**Томск, 26–28 мая 2022 г.**

*Под общей редакцией*  
*кандидата технических наук И.С. Шмырина*

Томск  
Издательство Томского государственного университета  
2022

# РАЗРАБОТКА СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ АНАЛИЗА ПАТОЛОГИЙ ЛЕГКИХ НА РЕНТГЕНОВСКИХ СНИМКАХ

**Подерни А.Ю., Конев Д.А.**

*Томский государственный университет*  
poderniaf@gmail.com, megahappyred@gmail.com

## Введение

В условиях пандемии нагрузка на систему здравоохранения повышается значительно. Увеличился спрос на различные медицинские исследования, при этом количество специалистов, которые осуществляют эти исследования, не может своевременно увеличиться вслед за спросом. Нехватка специалистов приводит к дополнительной нагрузке на тех, кто в данный момент занимается выявлением заболеваний: врач вынужден оказать помощь большому числу людей, при этом уделяя меньше внимания каждому отдельному пациенту. Он может устать, упустить из виду важные детали, что напрямую влияет на процесс выздоровления пациента. Именно поэтому сфера медицины является одной из наиболее нуждающихся в применении современных информационных технологий: это могло бы облегчить выполнение рутинных обязанностей врача и ускорить процесс постановки диагноза.

Перспективным инструментом для выявления патологий на медицинских изображениях является применение искусственных нейронных сетей. Способность решать достаточно сложные задачи позволяет проводить эксперименты над обработкой и анализом изображений, в частности, нейронные сети показывают свою эффективность также и в категории медицинских снимков.

Целью данной работы является создание системы поддержки принятия решений для анализа патологий легких на рентгеновских снимках с применением методов глубокого обучения. Для достижения данной цели были поставлены следующие задачи:

- произвести анализ архитектур нейронных сетей в рамках задачи классификации медицинских изображений;
- выбрать набор данных и подготовить его для обучения;
- провести необходимые эксперименты;
- выполнить сравнение качества классификации выбранных нейронных сетей как между собой, так и в зависимости от изменений в обучающем наборе данных;
- разработать прототип сервиса с возможностью загрузки пользователем своего рентгеновского снимка легких для дальнейшей классификации нейросетью;
- добавить отображение тепловой карты признаков, на основании которых нейронная сеть принимает решение о классификации.

## 1. Архитектуры нейронных сетей в задачах классификации медицинских изображений

Наиболее распространенные архитектурные решения для задач классификации медицинских изображений представлены в табл. 1.

AlexNet является классической архитектурой сверточной нейронной сети, оказавшей большое влияние на развитие машинного обучения. В конкурсе по распознаванию изображений ImageNet в 2012 г. модель показала впечатляющие результаты и победила остальных конкурентов с большим отрывом. Однако за прошедшее десятилетие появилось большое количество решений, превосходящих AlexNet как по точности предсказаний, так и по оптимизации параметров сети. В данный момент архитектура AlexNet за счет своей простоты применяется, в основном, в случаях, когда достижение большей

точности не является необходимым – например, при исследовании зависимости точности классификации изображений от методов предварительной обработки изображений [1].

Таблица 1

Архитектуры нейронных сетей в задачах классификации

| Архитектура                  | Автор                                                     | Количество слоев | Число параметров | Объем памяти | Особенность                                                                          |
|------------------------------|-----------------------------------------------------------|------------------|------------------|--------------|--------------------------------------------------------------------------------------|
| AlexNet [2]                  | Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, 2014 | 8                | 61 Million       | 233.10 MB    | Классическая архитектура сверточной нейронной сети                                   |
| GoogLeNet (Inception-V1) [3] | Christian Szegedy, Wei Liu, Yangqing Jia, 2014            | 22               | 7 Million        | 49.73 MB     | Ширина и глубина сети увеличились, количество параметров сократилось в несколько раз |
| ResNet [4]                   | Kaiming He, Xiangyu Zhang, Shaoqing Ren, 2015             | 152              | 60 Million       | 230.34 MB    | Первая “остаточная” нейронная сеть                                                   |
| Inception-ResNet-V2 [5]      | Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, 2016  | 164              | 56 Million       | 213.41 MB    | Объединение архитектур семейств Inception и ResNet                                   |
| DenseNet-121 [6]             | Gao Huang, Zhuang Liu, Laurens van der Maaten, 2017       | 121              | 8 Million        | 30.84 MB     | Развитие класса моделей ResNet                                                       |

GoogLeNet и ResNet также становились победителями ImageNet Large Scale Visual Recognition Challenge в 2014 и 2015 гг. соответственно. Сеть GoogLeNet положила начало семейству архитектур Inception, главной целью которых было повышение производительности моделей как по скорости, так и в точности предсказаний.

Архитектура ResNet совершила очередную революцию в развитии нейронных сетей. Во время каждой итерации обучения нейронной сети все веса получают обновление, пропорциональное частной производной функции ошибки по отношению к текущему весу. Если градиент очень мал, то веса не будут эффективно изменяться, и это может полностью остановить нейронную сеть от дальнейшего обучения. Это явление называется исчезающими градиентами. ResNet показала себя как архитектура, способная бороться с ними. Идея заключается в том, чтобы взять пару слоёв (например, сверточных), и добавить дополнительную связь, которая проходит мимо этих слоев.

Архитектура Inception-ResNet-V2 является попыткой объединить достоинства архитектур семейств Inception и ResNet. Согласно исследованиям [5], полученным авторами данной сети, у неё получилось превзойти предыдущие модификации модели Inception (рис. 1).

| Network             | Top-1 Error | Top-5 Error |
|---------------------|-------------|-------------|
| BN-Inception [6]    | 25.2%       | 7.8%        |
| Inception-v3 [15]   | 21.2%       | 5.6%        |
| Inception-ResNet-v1 | 21.3%       | 5.5%        |
| Inception-v4        | 20.0%       | 5.0%        |
| Inception-ResNet-v2 | 19.9%       | 4.9%        |

Рис. 1. Результаты экспериментов на наборе данных ImageNet

Архитектура DenseNet (“плотная” сверточная сеть) является развитием моделей класса ResNet – авторами было предложено соединить каждый слой нейронной сети с каждым другим слоем (рис. 2), за счет чего сеть получается более компактной, “плотной”. При этом количество параметров сети оказалось значительно меньшим относительно архитектур, показывающим такую же точность классификации.




Рис. 2. Один плотный блок DenseNet с пятью слоями

Для дальнейших экспериментов авторами данной статьи были выбраны архитектуры сетей Inception-ResNet-v2 и DenseNet как наиболее точные и, при этом, оптимизированные относительно своих предшественников сети.

### 2. Выбор данных для обучения

Помимо архитектуры нейронной сети, на точность классификации влияют также и данные, на которых она обучается: необходимо, чтобы набор изображений был достаточно большим, чтобы результат обучения имел высокую точность и практическую значимость. С этой целью за основу был взят наибольший из представленных в свободном доступе наборов данных – NIH Chest X-rays Dataset [7], представляющий собой 112120 рентгеновских снимков грудной клетки. Примерно половина снимков принадлежит здоровым людям и помечена меткой “No Finding”. На оставшихся снимках представлены 14 различных классов заболеваний, при этом классы являются пересекающимися – у одного человека может быть выявлено сразу несколько патологий. Классы и количество соответствующих им изображений представлены в табл. 2.

В связи с недостаточной представленностью некоторых патологий относительно величины набора, наименьшие категории болезней (выделенные в табл. 2 полужирным курсивом) были объединены в одну группу “Other” (табл. 3). Предполагалось, что для каждой из этих небольших категорий не получится достичь приемлемого качества классификации, и их объединение может улучшить средние показатели точности модели. Кроме того, для экспериментов был создан ещё один набор изображений, в котором категория “Other” полностью исключалась.

Таблица 2

Набор данных NIH Chest X-rays

|             |                     |          |              |      |        |                  |              |               |              |                  |                 |                           |               |
|-------------|---------------------|----------|--------------|------|--------|------------------|--------------|---------------|--------------|------------------|-----------------|---------------------------|---------------|
| Atelectasis | <b>Cardiomegaly</b> | Effusion | Infiltration | Mass | Nodule | <b>Pneumonia</b> | Pneumothorax | Consolidation | <b>Edema</b> | <b>Emphysema</b> | <b>Fibrosis</b> | <b>Pleural Thickening</b> | <b>Hernia</b> |
| 16057       | <b>3906</b>         | 18974    | 25366        | 8269 | 8409   | <b>2092</b>      | 7134         | 7177          | <b>3443</b>  | <b>3586</b>      | <b>2211</b>     | <b>5172</b>               | <b>284</b>    |

Набор данных NIH Chest X-rays с объединенными категориями

| Atelectasis | Effusion | Infiltration | Mass | Nodule | Pneumothorax | Consolidation | Other |
|-------------|----------|--------------|------|--------|--------------|---------------|-------|
| 16057       | 18974    | 25366        | 8269 | 8409   | 7134         | 7177          | 20694 |

Таким образом, дальнейшие эксперименты проводились на двух наборах данных:

1. Набор NIH Chest X-Rays, в котором малые группы патологий были объединены в одну общую категорию “Other”.
2. Набор NIH Chest X-Rays, в котором малые группы патологий были полностью исключены.

### 3. Эксперименты

Искусственные нейронные сети были реализованы на языке Python с применением библиотек Tensorflow и Keras. Для избежания проблем, связанных с недостаточно высокой вычислительной мощностью оборудования, на котором производилось обучение, использовались предобученные на наборе данных ImageNet модели InceptionResNetV2 и DenseNet121, доступные в библиотеке Keras. Обучение проводилось для изображений с размерностью 224x224x1. В качестве алгоритма оптимизации был выбран алгоритм Adam, эффективный для больших нейросетевых моделей.

В первую очередь было произведено обучение модели DenseNet121 на двух описанных ранее наборах данных. Для анализа результатов обучения были построены ROC-кривые, отражающие качество классификации для каждого типа патологий (рис. 3). Данный тип графиков отображает соотношение между долей объектов от общего количества носителей признака, верно классифицированных как несущие признак (True Positive Rate), и не несущих признака, но ошибочно классифицированных как несущие признак (False Positive Rate).

Анализ графиков показал, что удаление из набора данных небольших классов не привело к улучшению качества модели – качество классификации при объединении малых классов в один показывает более высокие результаты.




Рис. 3. ROC-кривая для набора данных с объединенными категориями заболеваний (слева), с удаленными категориями заболеваний (справа) при обучении модели DenseNet121

Затем было проведено обучение модели InceptionResNetV2 на первом наборе данных (рис. 4) для сравнения с результатами обучения модели DenseNet121. Как видно из графика, результаты обучения характеризуют ее непригодной для классификации. Бли-

зость кривых к диагональной прямой говорит о том, что метод классификации по своей сути близок к случайному гаданию.




Рис. 4. ROC-кривая для набора данных с объединенными классами при обучении модели InceptionResNetV2

Таким образом, по результатам эксперимента наибольшую точность показала архитектура DenseNet121, обученная на наборе данных NIH Chest X-rays, в котором наименьшие по объему данных классы были объединены в один общий класс.

#### 4. Визуализация тепловых карт активации классов

Для отображения пользователю веб-приложения признаков, на основании которых нейронная сеть приняла решение об отнесении снимка к определенной категории, был выбран метод, описанный в статье “Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization” [8]. Суть этого метода визуализации заключается в создании тепловых карт активации класса. Тепловая карта представляет собой 2D-сетку, в каждой ячейке которой располагается значение количества баллов, связанных с конкретным выходным классом. Эти баллы вычисляются для каждой части исходного изображения и отражают важность вклада этого участка в классификацию объекта выходного класса. На рис. 5 представлен пример входного изображения и построенная для него тепловая карта активации класса.




Рис. 5. Входное изображение (слева) и тепловая карта активации класса (справа)

## 5. Web-приложение

При проектировании приложения было выбрано решение с отдельной клиентской и серверной частью. Это довольно популярный подход, который применяют многие компании при разработке приложений, в связи с тем, что он позволяет легко масштабировать систему. Клиентская часть была построена с использованием технологии SPA, запросы к серверной части отсылаются через REST API. Авторизация пользователей проходит с помощью JWT-токенов. На серверной части используется MVC-архитектура, позволяющая разделить данные, логику и представление. Представление возвращает данные в JSON-формате.

При разработке приложения были использованы следующие инструменты:

- 1) ReactJS – JavaScript библиотека для создания клиентской части приложения;
- 2) Django – Python-фреймворк для разработки серверной части приложения;
- 3) PostgreSQL – система управления базой данных;
- 4) NodeJS – программная платформа для упрощения взаимодействия между клиентской и серверной частями приложения;
- 5) Redis – система управления хранилищем для кэширования данных.

На рис. 6 представлен главный экран разработанного веб-приложения, который предоставляет пользователю загрузить на сервер рентгеновский снимок легких. После загрузки изображения пользователю отображается переданный им снимок и результат работы нейронной сети – вероятность присутствия на снимке патологий (рис. 7). При нажатии на название патологии отображается тепловая карта активации класса, показывающая, какая область изображения распознается нейронной сетью как содержащая признаки данной патологии (рис. 8).



Рис. 6. Главный экран приложения





Рис. 7–8. Экран результатов работы нейронной сети.

При нажатии на одну из патологий отображается тепловая карта активации класса

## Заключение

В ходе данной работы разработана система поддержки принятия решений для анализа патологий легких на рентгеновских снимках как один из возможных способов помощи врачам в условиях повышения частоты легочных заболеваний и увеличения нагрузки на рентгенологов. Проведен анализ современных методов классификации медицинских изображений и найдены наиболее перспективные архитектуры нейронных сетей для решения поставленной задачи. Для данных архитектур проведена серия экс-



периментов, в ходе которых выявлена наиболее перспективная модель нейронной сети, показывающая более высокую точность классификации на выбранном наборе данных. Разработан сервис для анализа пользовательских рентгеновских изображений с помощью выбранной нейронной сети. Реализована визуализация тепловых карт активации класса для выделения на снимке признаков, на основании которых нейронная сеть относит изображение к определенному классу.

## ЛИТЕРАТУРА

1. *Ефремов А.А.* Поиск аномалий в рентгеновских снимках при помощи глубокого машинного обучения с использованием предварительной обработки снимков для сегментации легких и удаления костей [Электронный ресурс] URL: [https://dspace.spbu.ru/bitstream/11701/13400/1/Bachelor\\_s\\_graduation\\_work\\_-\\_diploma-final.pdf](https://dspace.spbu.ru/bitstream/11701/13400/1/Bachelor_s_graduation_work_-_diploma-final.pdf)
2. *Krizhevsky A.* ImageNet Classification with Deep Convolutional Neural Networks [Электронный ресурс] URL: <https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>
3. *Szegedy Ch.* Going deeper with convolutions [Электронный ресурс] URL: <https://arxiv.org/pdf/1409.4842v1.pdf>
4. *He K.* Deep Residual Learning for Image Recognition [Электронный ресурс] URL: <https://arxiv.org/pdf/1512.03385v1.pdf>
5. *Szegedy Ch.* Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning [Электронный ресурс] URL: <https://arxiv.org/pdf/1602.07261v2.pdf>
6. *Huang G.* Densely Connected Convolutional Networks [Электронный ресурс] URL: <https://arxiv.org/pdf/1608.06993v5.pdf>
7. *NIH Chest X-rays* [Электронный ресурс] URL: <https://www.kaggle.com/datasets/nih-chest-xrays/data>
8. *Selvaraju R.R.* Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization [Электронный ресурс] URL: <https://arxiv.org/abs/1610.02391>

DOI: 10.17223/978-5-907572-27-0-2022-35

## РАЗРАБОТКА КЛАССИФИКАТОРА ИЗОБРАЖЕНИЙ ГРИБОВ НА ОСНОВЕ ДВУХ НЕЙРОННЫХ СЕТЕЙ

**Филатьева Ю.В., Бронер В.И.**

*Томский государственный университет*  
ju.fila9@gmail.com valsubbotina@mail.ru

### Введение

Над вопросами классификации изображений работали многие авторы в разных предметных областях. Для распознавания изображений используются такие классические методы как байесовские классификаторы [1], корреляционный метод [2]. Использование классических методов трудозатратно в связи с необходимостью определения, выявления признаков каждого класса изображений вручную, что в случае сложных изображений проблематично. Альтернативным методом анализа изображений являются нейросети.

На данный момент в области распознавания изображений грибов уже существуют аналоги, представленные на рынке приложений. Однако каждое из этих приложений распознает и классифицирует предоставленный пользователем гриб исключительно по одному изображению. Подобный подход также приемлем, однако у грибов есть важные особенности, которые в определенных случаях невозможно выделить, используя при распознавании один ракурс фотографии. Данный подход имеет свои погрешности, количество которых можно сократить, если использовать хотя бы два изображения для классификации.

В данной работе использован метод, позволяющий уменьшить количество ошибок при классификации гриба по одному изображению. Он представлен как объединение работы двух нейронных сетей, каждая из которых классифицирует по одному ракурсу, с которого был сфотографирован гриб – одна нейронная сеть распознает гриб сверху, а вторая – сбоку. Такой подход позволяет уменьшить количество ошибочных предска-