

ПОСТРОЕНИЕ АЛГОРИТМОВ ДЛЯ ОБНАРУЖЕНИЯ ВНЕЛЕГОЧНЫХ ПАТОЛОГИЙ НА РЕНТГЕНОВСКИХ ИЗОБРАЖЕНИЯХ ГРУДНОЙ КЛЕТКИ

А. Г. Раджабов, В. А. Ковалев

ОИПИ НАН Беларуси, Минск, Беларусь

E-mail: axmegxah@outlook.com, vassili.kovalev@gmail.com

Одной из важных проблем при решении задач автоматизации классификации медицинских изображений является подготовка данных. В результате работы над базой изображений повышена производительность итогового алгоритма с 75% до 95%. Обработка всего объема получаемых изображений и проведение их диагностики по широкому списку патологий затруднены для медицинских учреждений ограниченной ресурсами. В связи с чем целесообразно использовать автоматизацию процессов сегментации и распознавания, что уже на первых этапах развития технологии дает возможность перераспределить внимание врачей, заостряя их внимание на потенциально патологических случаях и возвращая внимание к случаям, ошибочно идентифицированным как непатологические.

Ключевые слова: *глубокое обучение, внелегочные патологии, подготовка данных, предобученные нейронные сети, классификация.*

ВВЕДЕНИЕ

Закрепившаяся практика плановых рентгенологических исследований и постепенное вытеснение аналоговых способов регистрации изображений цифровыми приводит к накоплению цифровых баз изображений и открывает возможность быстрой обработки таких данных. Развитие компьютерной техники и доступность микросервисных и облачных технологий сделали обработку данных возможной практически при любом масштабе применения технологий автоматизированной работы с биомедицинскими изображениями. Обозначенный процесс информатизации компенсирует замедление в развитии базовых технических компонентов. Наиболее заметные успехи, в последнее время, наблюдаются в сфере машинного зрения. Оно внедряется как для автоматизации внутренних процессов медицинских учреждений, так и для обработки медицинских данных и получения новых, ранее недоступных признаков из данных [1]. Часто, взамен алгоритмам цифровой фильтрации и построения жестко запрограммированных моделей, применяются методы машинного обучения [2]. Одной из перспективных областей применения машинного обучения является машинное распознавание и классификация изображений и объектов на них. Несмотря на свою долгую историю данные системы и алгоритмы машинного обучения только начинают заполнять ниши в ме-

дицинской практике. Это связывают, во многом, с тем, что возможность применения таких систем технически открылась только недавно, но все еще существует недостаток систематизированных знаний в процессах патогенеза, анатомии и других сферах [3]. Последнее, при наличии большого набора экспериментальных данных преодолимо с помощью алгоритмов глубокого обучения, еще называемых нейросетевыми алгоритмами [4]. Отсутствие универсальных (генерализированных) наборов данных, а также недостаток аннотированных данных формирует необходимость в проведении исследования возможностей нейросетевых подходов для конкретных наборов данных.

ПОДГОТОВКА ДАННЫХ

Исходной базой данных выступала база рентгеновских изображений грудной клетки лаборатории анализа биомедицинских изображений ОИПИ НАН Беларуси, содержащая более 2 млн. изображений, аннотированных текстом врачами (наличие заболеваний, возраст, пол и другие полезные данные). Из нее были получены базы изображений: I – набор, содержащий два класса – изображения со всеми внелегочными патологиями и остальные изображения (условно – без патологий), в ходе экспериментов в ней выявились некоторые недостатки, которые были учтены в ходе составления новых наборов, II – наборы, состоящие из изображений с признаками (одним признаком) одной внелегочной патологии и изображений, не содержащих признаков каких-либо патологий (во всех случаях определяющим фактором для признаков патологий являлись данные из аннотации).

Во втором наборе данные формировались и разделялись на тренировочные и тестовые с соблюдением эксклюзивности изображений пациента для обозначенных наборов данных (непопадание изображений одного пациента в тренировочный и тестовый набор данных одновременно) и случайности распределения, для предотвращения влияния непредусмотренных факторов. Также, из наборов были удалены изображения, не удовлетворительного качества (с ярко выраженными артефактами, слишком темные, светлые и потерявшие информативность). Для формирования перечисленных суб-наборов данных использовались следующие метки из аннотации: сердце расширено, аорта развернута, аорта уплотнена, тень сердца расширена, склероз дуги аорты, сглаженная талия, атеросклероз аорты, сосудистые корни, сколиоз и другие. Из перечисленных наборов и из общего набора изображений без признаков патологий были исключены изображения, со следующими метками: пневмосклероз, спондилез, эмфизема, фиброз, тяжесть корней легких, релаксация купола легких, деформация ребер, кальциноз, пневмония, апикальные наложе-

ния, ПДС, очаговые тени, петрификаты, бронхит, усиление легочного рисунка, корни обог., туберкулез. Ввиду лучшего качества выборки (чистоты от изображений другого класса), для формирования наборов данных были выбраны только рентгенограммы женщин. После формирования наборов данных они были нормализованы.

ВЫЧИСЛИТЕЛЬНЫЙ ЭКСПЕРИМЕНТ

Для достижения репрезентативного результата был использован фреймворк MONAI, предназначенный для имплементаций искусственного интеллекта или глубокого обучения на медицинские данные. На первоначальном этапе использовалась база, содержащая все внелегочные патологии как один класс. Сходимость на таком наборе не была достигнута, площадь под ROC-кривой, в лучшем случае, составляла 75% [5]. Среди нескольких моделей нейронных сетей, таких как `densenet121`, `senet154`, `se_resnet50`, `se_resnext101_32x4d`, базовый классификатор MONAI и вариаций EfficientNet, в том числе предобученных на рентгеновских изображениях, наиболее стабильный результат показали последние (вариации EfficientNet). Поэтому они использовались для всех последующих экспериментов, произведенных с новыми наборами данных. EfficientNet была разработана в ходе изучения и поиска баланса гиперпараметров нейросетевых моделей [6]. Для EfficientNet-B4 использовалось разрешение 380x380.

Таблица 1

Наименование набора данных	AUC	Accuracy	Precision	Recall	f1-score
Расширенное сердце	0.9667	0.9102	0.9118	0.9102	0.9107
Тень сердца расширена	0.9956	0.9754	0.9757	0.9754	0.9755
Аорта развернута	0.9732	0.9156	0.9190	0.9156	0.9161
Аорта уплотнена	0.9641	0.8952	0.8961	0.8952	0.8955
Атеросклероз аорты	0.9987	0.9829	0.9829	0.9829	0.9829
Релаксация купола	0.9335	0.8594	0.8594	0.8594	0.8594
Склероз дуги аорты	0.9820	0.9572	0.9574	0.9572	0.9573
Сколиоз	0.9495	0.8804	0.8795	0.8804	0.8786
Сосудистые корни	0.9849	0.9362	0.9400	0.9362	0.9367

Вычисления производились на видеоускорителях Nvidia GeForce RTX 2070 и GeForce GTX TITAN X с 8 и 11 ГБ видеопамяти соответственно. Прогоны всех датасетов, сбалансированных по классам больных и здоровых, с использованием EfficientNet-B4 и 20 эпох, произведенных на GeForce GTX TITAN X, заняли, в совокупности, около 50 часов.

Производительность для соответствующих наборов данных, достигнутая в ходе экспериментов приведена в таблице 1, где AUC – площадь

под ROC-кривой, accuracy - доля правильных ответов, precision – точность, recall – полнота, f1-score - среднее гармоническое precision и recall. Для precision, recall и f1-score приведены средневзвешенные значения.

ВЫВОДЫ

Общие показатели подтвердили улучшение качества набора данных и позволяет сосредоточиться на улучшении всего алгоритма классификации.

На этапе подготовки изображений, нормализация вскрыла некоторые артефакты изображений и, возможно, усилила некоторые графические проблемы, такие как высокая контрастность, контрастные горизонтальные линии, излишняя яркость, либо тусклость изображений. Борьбе с данными проблемами было отдано значительное время и полученный лучший результат применен в процессе экспериментов, но, вероятно, возможно получить существенно лучший результат в этой области.

В дальнейшем предполагается исследовать возможности построения сетей для обучения без учителя, параллельное обучение классификации и сегментации нескольких классов, а также использования архитектур siamois сетей для поиска паттернов и улучшения итогового результата классификатора.

БИБЛИОГРАФИЧЕСКИЕ ССЫЛКИ

1. Канюков В.Н. Компьютерные технологии в медико-биологических исследованиях Часть 1 : учебное пособие. – Оренбург: ГОУ ОРИ, 2009. – 109 с.
2. Shorliffe E.H. Computer-based medical consultations. New York: MYCIN, Elsevier scientific publishing company, 1976. – 263 p.
3. Пеккер Я.С. Компьютерные технологии в медико-биологических исследованиях. Сигналы биологического происхождения и медицинские изображения: учебное пособие. – Томск: Изд. ТПУ, 2002. 240 с. – с.7.
4. Гудфеллоу Я.Д. Глубокое обучение : учебное пособие. – СПб: ДМК, 2017. –652 с.
5. Radzhabov A., Kovalev V., Performance Analysis of Deep Learning Models for Heart Segmentation in Chest X-ray Images on a Small Dataset // International Conference on Pattern Recognition and Information Processing. 2021.
6. Tan M., Le Q.V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks // arXiv, 2020. – Режим доступа: <https://arxiv.org/pdf/1905.11946.pdf> – Дата доступа: 25.11.2021.