

ЭТАПЫ КОНТРОЛЯ ВХОДНЫХ ДАННЫХ ПРИ РАБОТЕ СИСТЕМЫ АВТОМАТИЧЕСКОГО ВЫЯВЛЕНИЯ ПАТОЛОГИЙ ЛЕГКИХ

А.А. Косарева^{1,2}, Д.А. Павленко², Э.В. Снежко², В.А. Ковалев²

¹*Белорусский государственный университет информатики и радиоэлектроники,
ул. П. Бровки, 6, 220013, г. Минск, kosareva@bsuir.by*

²*Объединенный институт проблем информатики Национальной академии наук
Беларуси, ул. Сурганова, 6, 220012, г. Минск, vassili.kovalev@gmail.com,
<https://image.org.by>*

Предварительная обработка и отсеивание поступающих данных в систему компьютерной диагностики заболеваний легких является важным этапом, так как напрямую влияет на работу приложения и на отношение пользователя к получаемым результатам. В данном докладе предлагается алгоритм верификации изображений компьютерной томографии (КТ) органов грудной клетки человека, включающий в себя набор тривиальных и нетривиальных чекеров. Наибольшее внимание уделяется нейросетевым методам. Разработанный модуль контроля входных данных имеет точность классификации 100 % на тестовом наборе данных для проверки модальности и точность классификации 89 % на тестовом наборе данных для проверки наличия легких.

Ключевые слова: классификация изображений; медицинская визуализация; сверточная нейронная сеть; глубокое обучение; компьютерная диагностика; компьютерная томография; проверка входных данных.

STAGES OF INPUT DATA CONTROL DURING THE WORK OF AUTOMATIC LUNG PATHOLOGY DETECTION SYSTEM

A.A. Kosareva^{1,2}, D.A. Paulenka², E.V. Snezhko², V.A. Kovalev²

¹*Belarusian State University of Informatics and Radioelectronics, 6 P. Brovki st., 220013,
Minsk, Belarus, kosareva@bsuir.by*

²*The United Institute of Informatics Problems of the National Academy of Sciences
of Belarus, 6 Surhanava st., 220012, Minsk, Belarus, vassili.kovalev@gmail.com,
<https://image.org.by>*

Pre-processing and verification of incoming data into a computer-aided diagnosis system of lung diseases is an important step, as it directly affects the output of the application and the user's attitude to the obtained result. This report proposes a chest computed tomography (CT) checking algorithm that includes a set of trivial and non-trivial verification tools. The greatest attention is paid to neural network methods. The result of the developed input data control module is 100% classification accuracy on the modality check dataset and 89% classification accuracy on the lung presence check dataset.

Keywords: Image Classification; Medical Imaging; Convolutional Neural Network; Deep Learning; Computer-Aided Diagnosis; Computed Tomography; Input Validation.

Введение

Методы искусственного интеллекта позволяют реализовывать сложные системы второго мнения при автоматизированной диагностике различных заболеваний. Одной из сложностей использования таких инструментов в реальной практике являются некорректные входные данные. При работе с подобными системами на вход может быть подано изображение другой модальности или другой части тела, что приведет к некорректным результатам при работе системы. Например, в одном испытании среди 7830 рентгенограмм грудной клетки, полученных из различных больниц десяти стран, было 564 случая, содержащих ошибочные данные такого рода [1]. Также входные данные могут содержать ряд других ошибок: ошибка расположения, ошибка формата файла, инвертированное изображение и т.д. [2–4]. В связи с этим возникает необходимость разработки алгоритма контроля входных данных, который отсеивает некорректные изображения, загружаемые пользователем.

Разработанный алгоритм предназначен для системы обработки изображений компьютерной томографии (КТ) легких и включает в себя следующие этапы:

1. Последовательность тривиальных проверок, таких как: проверка размерности трехмерного изображения, проверка формата поступающего файла, проверка гистограммы яркости изображений на наличие разброса значений в динамическом диапазоне, проверка минимального размера входного изображения (количество слоев должно быть не менее 25), дополнительная проверка тегов DICOM-изображений, если поступающее изображение пришло в формате DICOM.

2. Проверка модальности. Входное изображение должно являться КТ, а не изображением УЗИ, ПЭТ, МРТ или бинарной маской;

3. Проверка анатомической области. Необходимо убедиться, что входное КТ-изображение содержит легкие в необходимой пропорции для обработки приложением.

1. Методология исследования / теоретические основы

Тривиальные проверки

На рисунке 1 представлен алгоритм тривиальных проверок, позволяющий отсеять изображения, не соответствующие требованиям разработанной интеллектуальной системы.




Рисунок 1 – Алгоритм тривиальных проверок входных данных

Разработанная интеллектуальная система принимает трехмерные изображения, содержащие серию срезов компьютерной томографии разрешением 512×512 пикселей. При подаче изображений низкого разрешения и малого количества срезов, высока вероятность получить некорректный ответ на выходе системы. Поэтому были установлены минимальные значения разрешения и количества срезов в поступающих на вход трехмерных объемах. Решение об отклонении входного изображения от дальнейшей обработки принимается на каждом этапе алгоритма.


Нетривиальные проверки

Для разработки системы контроля входных КТ-изображений легких использовалось два набора данных:


1. 506 изображений разных модальностей (КТ, УЗИ, ПЭТ, МРТ, бинарные маски, маммографические изображения);
2. 668 КТ-изображений разных частей тела (легкие, голова, конечности, абдоминальная область, пустые изображения, шум и т.д.).

Изображения, входящие в подготовленные наборы данных, были взяты из открытых источников [5].

Для разработки модуля проверки модальности и модуля проверки наличия легких на КТ-изображении использовались методы глубокого обучения, основанные на тренировке сверточных нейронных сетей (CNN). Архитектуры используемых CNN представлены на рисунке 2.а для решения задачи проверки модальности и на рисунке 2.б для проверки наличия легких на КТ-изображении.



a)



б)

Рисунок 2 – а) Одноблочная CNN для проверки модальности изображения;
б) четырехблочная CNN для проверки наличия легких на КТ-изображении

Параметры нейронной сети для проверки модальности (рисунок 2.а) подбирались на практике в ходе многочисленных испытаний. Исследование показало, что входной слой с разрешением ~~64~~64×64 и сверточный слой с 25 фильтрами оказались приемлемыми. Входные изображения

нормализуются и случайно вращаются на 90, 180 и 270 градусов вокруг трех осей, что исключает неточности, связанные с поворотом изображения.

Перед подачей на вход нейронной сети для проверки наличия легких на КТ-изображении (рисунок 2.б) изображение проходит серию предварительных обработок. Сначала к изображению применяется порог [-1500, 500] для единиц Хаунсфилда [6]. Затем изображение нормализуется к диапазону [-1, 1]. Изменяется размер на 128×128×128 пикселей. После чего к изображению применяется серия трехмерных поворотов и отражений.

2. Результаты и их обсуждение

При решении задачи проверки модальности КТ-изображений достигла 100 % точности классификации на тестовом наборе данных. Модель была обучена три раза, состав обучающей выборки менялся при каждом обучении, это не повлияло на точность классификации. Соответственно можно сделать вывод, что результаты прогнозов модели не зависят от состава данных в обучающей выборке. Анализируя 100% точность проверки модальности КТ-изображений, мы обратились к результатам аналогичного исследования для проверки модальности рентгеновских изображений. В ходе экспериментов выяснилось, что тот же метод показал точность менее 70% для рентгеновских изображений. Для улучшения результата нам пришлось увеличить обучающую выборку до 1000 изображений для каждого класса и использовать более продвинутую архитектуру CNN (EfficientNet). Это позволило достичь точности классификации в 99,8%. Поэтому мы предполагаем, что признаки КТ-изображений имеют ряд существенных отличий от признаков МРТ, УЗИ, бинарных масок, гистологических изображений и т.д.

При решении задачи проверки наличия легких на КТ-изображениях обученная нейронная сеть имеет точность классификации 89 % на тестовом наборе данных. Анализ ошибочных прогнозов показал, что CNN ошибочно классифицирует изображения биопсии легких. Семь из девяти (настоящих и искусственно созданных) КТ-биопсий были неверно отнесены к классу «легкие». Возможная причина, по которой КТ-биопсии неправильно классифицируются как «легкие», заключается в том, что их осевой аксиальный вид не отличается от обычных легких. Однако коронарный и сагиттальный виды имеют большие отличия.

Заключение

Обученные искусственные нейронные сети показали хорошие результаты и используются авторами для контроля входных данных в нейросетевом программном комплексе для поддержки принятия решений при диагностике заболеваний легких на основе рентгеновских и томографических изображений. Модуль контроля входных КТ-изображений имеет точность классификации 100 % на тестовом наборе данных для проверки модальности и точность классификации 89 % на тестовом наборе данных для проверки наличия легких. С помощью разработанного модуля авторы обнаружили девять КТ-изображений легких, которые были ошибочно помещены в набор данных КТ головы CQ500 [7]. Эти КТ-изображения легких были визуально проверены и добавлены в базу изображений легких для повышения точности обучения.

Библиографические ссылки

1. Rosenthal A, Gabrielian A, Engle E, Hurt DE, Alexandru S, Crudu V, Sergueev E, Kirichenko V, Lapitskii V, Snezhko E, Kovalev V, Astrovko A, Skrahina A, Taaffe J, Harris M, Long A, Wollenberg K, Akhundova I, Ismayilova S, Skrahin A, Mammadbayov E, Gadirova H, Abuzarov R, Seyfaddinova M, Avaliani Z, Strambu I, Zaharia D, Muntean A, Ghita E, Bogdan M, Mindru R, Spinu V, Sora A, Ene C, Vashakidze S, Shubladze N, Nanava U, Tuzikov A, Tartakovsky M. The TB Portals: an Open-Access, Web-Based Platform for Global Drug-Resistant-Tuberculosis Data Sharing and Analysis. *J Clin Microbiol.* 2017 Nov;55(11):3267-3282. DOI: 10.1128/JCM.01013-17. Epub 2017 Sep 13. PMID: 28904183; PMCID: PMC5654911.
2. Kaplan S., Handelman D., & Handelman A. Sensitivity of neural networks to corruption of image classification // *AI Ethics*. 2021. № 1, 425–434. doi.org/10.1007/s43681-021-00049-0.
3. Guan D., Yuan W., Lee Y.K., Lee S.: Identifying mislabeled training data with the aid of unlabeled data // *Appl. Intell.* 2011. № 35. P. 345–358.
4. Brady A.P.: Error and discrepancy in radiology: inevitable or avoidable? // *Insights Imaging*. 2017. № 8. P. 171–182.
5. Clark K., Vendt B., Smith K., Freymann J., Kirby J., Koppel P., Moore S., Phillips S., Maffitt D., Pringle M., Tarbox L., & Prior F. (2013). The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository // *Journal of Digital Imaging*, 2013. № 26(6). P. 1045–1057. doi.org/10.1007/s10278-013-9622-7
6. Zunair Hasib & Rahman, Aimon & Mohammed, Nabeel & Cohen, Joseph. // *Uniformizing Techniques to Process CT Scans with 3D CNNs for Tuberculosis Prediction*. 2020. DOI: 10.1007/978-3-030-59354-4_15.
7. Chilamkurthy S., Ghosh R., Tanamala S., Biviji M., Campeau NG., Venugopal VK., Mahajan V., Rao P., Warier P. Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. *The Lancet*. 2018, DOI: 10.1016/S0140-6736(18)31645-3.