

*А. А. Довганич¹, А. В. Хвостиков^{1,2}, А. С. Крылов^{1,2},
Л. Е. Паролина³*

МЕТОД АВТОМАТИЧЕСКОГО КОНТРОЛЯ КАЧЕСТВА РЕНТГЕНОГРАММ ЛЕГКИХ ДЛЯ ПРИМЕНЕНИЯ ГЛУБОКОГО ОБУЧЕНИЯ*

Введение

В последнее время все большее развитие и популярность получают методы анализа медицинских данных с привлечением глубоких нейронных сетей. Особенно актуальными являются методы, основанные на сверточных нейронных сетях, предназначенные для решения различных задач анализа изображений, таких как классификация, сегментация, детекция, поиск аномалий и т. д. Отсутствие необходимости в разработке специализированных алгоритмов для выделения и описания с точки зрения медицинского диагноза сложных структур на изображениях и отличная обобщающая способность делают нейросетевые методы анализа изображений удобными и эффективными.

Однако, принцип построения признаков напрямую из изображений, лежащий в основе современных сверточных нейронных сетей, делает подобные нейросетевые подходы крайне требовательными к качеству и однородности выборки изображений, на которой происходит обучение модели. Таким образом, актуальной на текущий момент задачей является анализ качества изображений, попадающих на вход нейросетевой модели, использующихся, как при обучении, так и при валидации. Из-за особенностей и широкого диапазона настроек медицинского оборудования, проблема контроля качества входных изображений актуальна для изображений различных модальностей, например для магнитно-резонансной томографии [1], компьютерной томографии [2], и рентгенографии [3].

В данной работе рассматривается проблема контроля «жесткости» рентгеновских изображений органов грудной клетки. Рентгенография используется для диагностики различных заболеваний легких, в частности - для диагностики туберкулеза [4, 5] и поражения легких при инфекции COVID-19 [6, 7, 8]. «Жесткость» рентгеновского снимка показывает, насколько правильно подобрана доза рентгеновского излучения для

¹ МГУ имени М. В. Ломоносова, факультет ВМК, a.dovganich@yandex.ru,
khvostikov@cs.msu.ru, kryvl@cs.msu.ru

² Московский Центр фундаментальной и прикладной математики,

³ «НМИЦ фтизиопульмонологии и инфекционных заболеваний» Минздрава России,
parolinale@nmrc.ru

* Работа выполнена при поддержке гранта РФФИ 19-57-80014 БРИКС_Т (BRICS2019-394)

конкретного больного. В зависимости от адекватности дозы облучения на рентгенограмме видны различные структурные особенности органов грудной клетки. При анализе и описании рентгенограммы рентгенологом всегда учитывается жесткость снимка, поскольку недооценка этого фактора может привести к неверному заключению. При обучении нейронной сети она подстраивается под жесткость снимков из обучающего набора. Следовательно, нейронная сеть, обученная на «жестких» снимках, покажет плохой результат, если ей на вход подать «мягкие» снимки и наоборот. Для решения этой проблемы в данной работе предлагается автоматизированный метод оценки жесткости рентгенограмм органов грудной клетки. На первом этапе это позволит фильтровать входные данные и отсеивать рентгенограммы, на которых модель классификатора будет заведомо некомпетентна. В дальнейшем же открывается возможность обучить несколько моделей классификаторов, ориентированных для работы со снимками разной жесткости, и производить распределение входных данных между ними.

Для разработки автоматизированного метода определения жесткости рентгеновских снимков было решено формализовать эмпирический метод, применяемый рентгенологами. Критерием оптимальной жесткости рентгеновских лучей для конкретного больного является отчетливая видимость 3-4 верхних грудных (а не любых) позвонков. Принято считать, что при повышенной жесткости («жесткий» снимок) имеет место четкое определение грудных позвонков ниже четвертого позвонка. Если на рентгенограмме грудной клетки четко контурируются менее трех верхних грудных позвонков, то это свидетельствует, что жесткость рентгенограммы снижена («мягкий» снимок) [9, 10].

С целью определения видимых позвонков был адаптирован автоматизированный метод нахождения позвоночника и выделения отдельных позвонков, применяемый на рентгенограммах позвоночника для определения сколиоза [11]. Рентгеновские снимки позвоночника и рентгенограммы органов грудной клетки несколько отличаются по формату, общему уровню освещенности, а также контрастности, поэтому некоторые этапы алгоритма для анализа изображений позвоночника были изменены или заменены. Для выявления и подсчета позвонков по уже выделенному позвоночнику использовался метод хребтовых структур (англ. ridges).

Формирование набора данных

Для разработки и тестирования метода были использованы наборы данных Montgomery [12], Shenzhen [12] и Open-I [13]. Снимки заведомо были получены на различном оборудовании с различными настройками и визуально имели отличающуюся «жесткость».

Набор данных Montgomery состоит из 138 изображений в оттенках серого с глубиной цвета 8 бит с разрешением $\sim 4000 \times 4900$ пикселей. Набор данных Shenzhen состоит из 662 изображений в оттенках серого с глубиной цвета 8 бит с разрешением $\sim 3000 \times 2900$. Для всех изображений есть клиническое описание диагностированных заболеваний. Набор данных Open-I несколько отличается, он состоит из 7470 изображений в оттенках серого с глубиной цвета 8 бит с разрешением 512×512 пикселей. В нем для 3955 изображений есть заключение рентгенолога.

Предобработка рентгеновских снимков

Искажение спектра освещенности при рентгенографии происходит не равномерно по всему изображению, а изменяется от области к области. Связано это прежде всего с тем, что рентгеновские лучи, проходя через исследуемый объект, ослабляются его различными частями по-разному. Степень ослабления их зависит от химического состава объекта, его плотности и толщины. Кроме того, с увеличением напряжения на рентгеновской трубке увеличивается проникающая способность рентгеновского излучения (его жесткость). С увеличением жесткости излучения увеличивается количество рассеянного излучения, которое является причиной появления на рентгеновских снимках диффузной вуали, что приводит к понижению контрастности изображения.

Существует три основных подхода к выравниванию освещенности на изображениях: нормализация, классическая эквализация гистограммы и адаптивная эквализация гистограммы. Нормализация работает на изображениях, где часть спектра полностью отсутствует (нет очень ярких или наоборот очень темных пикселей), что не соответствует наборам данных, используемым в данной работе. Стандартный метод эквализации гистограммы хорошо работает для изображений с очень низким общим контрастом. Однако гистограммы изображений рентгена легких охватывают весь спектр значений интенсивности и низкий контраст наблюдается в локализованных областях (рис. 1). Для решения проблемы выравнивания освещенности в локализованных областях был использован метод адаптивной эквализации гистограммы. Пример сравнения результатов применения всех трех алгоритмов для рентгеновского снимка легких с рис. 1 приведен на рис.2.




Рис. 1. Пример изображения рентгена легких.
 Прямоугольником выделена область с низким контрастом.

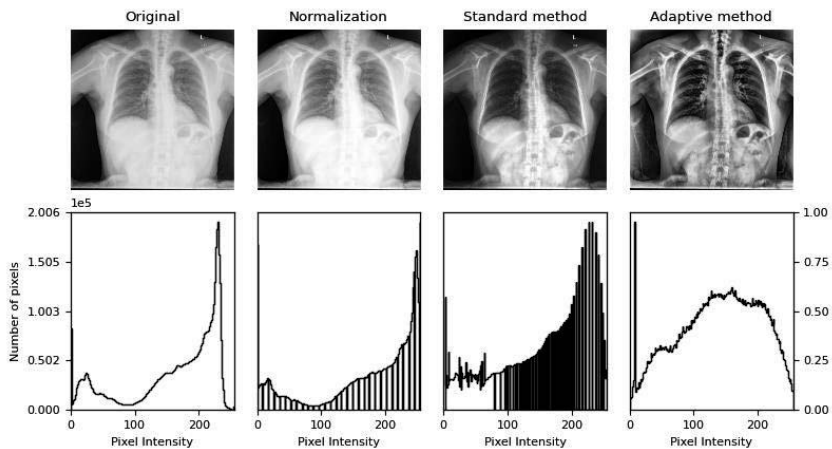


Рис.2. Пример применения различных алгоритмов выравнивания освещенности с соответствующими гистограммами полученных изображений

Определение области позвоночника

Первый этап разработанного метода состоит в изолировании области позвоночника, который реализован на основе нейросетевого подхода. Чтобы сделать обработку более эффективной, сначала размер всех изображений уменьшается до четверти от их исходного размера. Далее применяется нейросетевой метод выделения областей интереса при помощи прямоугольных областей. При помощи сервиса Amazon SageMaker Ground Truth была выполнена разметка изображений из исходных наборов данных. Результаты разметки получены в виде файла в формате json, где для каждого снимка указаны координаты прямоугольной области в относительных координатах. Затем объединенный набор данных был перемешан и разбит на тренировочную и тестовую выборки в соотношении 80% на 20%. Далее локально на видеокarte при помощи фреймворка глубокого обучения pytorch проведено дообучение модели resnet-34 [14] в течение 10 эпох. В качестве функции потерь при обучении использовалась функция L1-loss. Для оценки качества результатов работы нейросетевой модели после каждой эпохи дополнительно проводился подсчет меры качества Intersection over Union (IoU) на тренировочной и тестовой выборке. Результаты показали, что область позвоночника на изображениях рентгена легких локализуется вполне успешно. Результаты выделения области приведены в таблице 1.

Таблица. 1. Результаты работы алгоритма обнаружения области позвоночника

Эпоха	L1-loss тренировочная выборка	L1-loss тестовая выборка	IoU тренировочная выборка	IoU тестовая выборка
2	0.534	0.257	0.001	0.012
3	0.136	0.064	0.470	0.627
5	0.053	0.053	0.741	0.676
10	0.049	0.050	0.755	0.698

Нахождение центральной линии позвоночника и его границ

Следующим этапом после определения области позвоночника является нахождение на изображении отдельных позвонков. Их обнаружение состояло из трех шагов:

- 1) обнаружение центральной линии позвоночника (рис. 3а, 3в);
- 2) нахождение границ позвоночника (рис. 3б, 3в);
- 3) выделение отдельных позвонков.

Ниже приведен алгоритм обнаружения центральной линии позвоночника. Используются прямоугольные окна размером $H \times W$ передвигающиеся с шагом в один пиксель по горизонтали. Внутри каждого окна вычисляется сумма интенсивностей пикселей. Находится окно с наибольшей суммой интенсивностей. Верхняя средняя точка этого окна используется как первая точка отсчета для определения центральной линии позвоночника:

$$s(x, y) = \sum_{i=0}^H \sum_{j=-W/2}^{W/2} I(x + j, y + i),$$

$$(x_{max}, y_{max}) = \operatorname{argmax}_{(x,y)}(s),$$

где I – область изображения, содержащая позвоночный столб с размерами H_I и W_I , $H = \frac{H_I}{8}$, $W = \frac{W_I}{4}$, (x, y) – координаты окна (x – координата середины окна, y – координата нижней границы окна), $s(x, y)$ – сумма значений интенсивностей пикселей в окне, а (x_{max}, y_{max}) – координаты найденной точки.

Затем текущее прямоугольное окно перемещается вниз на p пикселей и производится поиск следующей контрольной точки в интервале q пикселей с обеих сторон с шагом в один пиксель. Верхняя средняя точка окна считается второй контрольной точкой центральной линии позвоночника. Вычисления повторяются до тех пор, пока не будет обнаружено n контрольных точек $(x_{c_i}, y_{c_i}), i = 1..n$. Заключительным этапом обнаружения центральной линии позвоночника является полиномиальная интерполяция по n обнаруженным контрольным точкам.

Далее проводится поиск границ позвоночника по оси x . Будем называть левой и правой границей позвоночника точки, находящиеся на границах позвонков (англ. edges), с координатами (x_{l_i}, y_{l_i}) и (x_{r_i}, y_{r_i}) , при $i = 1..n$, где $y_{l_i}, y_{r_i} = y_{c_i}$ и $x_{l_i} < x_{r_i}$. На этапе обнаружения левой и правой границы позвоночника используется два смежных окна одинакового размера, которые перемещаются не более чем на r пикселей по нормали к центральной линии позвоночника в каждую из сторон от центра. Верхняя середина смежных окон, между которыми разность интенсивности максимальна идентифицируется как точка границы позвоночника. Определение границ продолжается до тех пор, пока не будут исследованы все контрольные точки центральной линии позвоночника.

На заключительном этапе обнаружения левой и правой границы позвоночника производится полиномиальная интерполяция по n обнаруженным точкам с каждой стороны позвоночного столба. Здесь и при обнаружении центральной линии позвоночника используются полиномы третьей степени. Параметры метода были привязаны к размерам обрабатываемых изображений H_I и W_I :

$H = \frac{H_I}{8}, W = \frac{W_I}{4}, p = \frac{H}{4}, q = \frac{W}{2}, r = \frac{W_I}{2}$, где H_I – высота изображения в пикселях, а W_I – ширина. Пример работы алгоритма выделения позвоночника приведен на Рис. 3

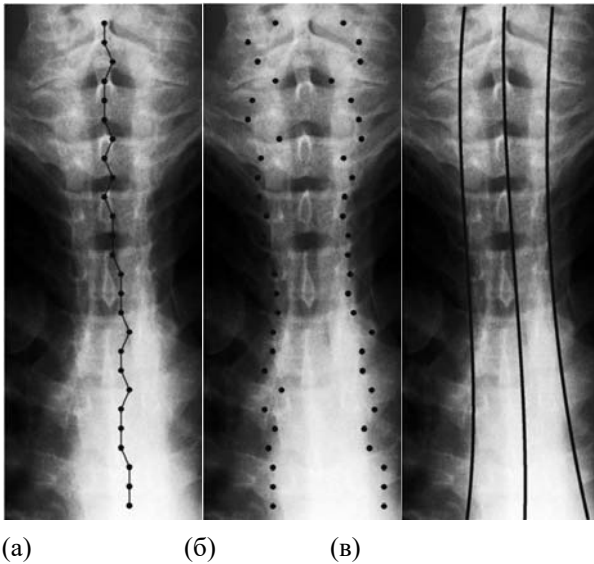


Рис.3. Нахождение центральной линии позвоночника и границ. (а) – центральная линия позвоночника, (б) – границы позвоночника, (в) – центральная линия позвоночника и границы после интерполяции

Выделение отдельных позвонков и подсчет их количества

Приведенная в [11] методика подсчета позвонков, хорошо себя показавшая для рентгеновских снимков позвоночника, на рентгеновских изображениях органов грудной клетки хороших результатов не показала. Это связано с тем, что для рентгенограмм легких используется меньшая доза излучения в отличие от снимков позвоночника. Поэтому вместо метода предложенного в [11] было решено построить модифицированную карту хребтовых структур. Карта строилась по следующему алгоритму:

1) нахождение вторых производных изображения;

2) составление попиксельной матрицы вида: $Q = \begin{pmatrix} L_{xx} & L_{xy} \\ L_{xy} & L_{yy} \end{pmatrix}$, где L - значения интенсивности исходного изображения;

3) нахождение собственных значений λ_1 и λ_2 матрицы Q , где $\lambda_1 > \lambda_2$;

4) построение 2-х карт хребтовых структур из значений λ_1 и $\lambda_2 - I_1$ и I_2 , где $I_i(x, y) = \frac{\lambda_i(x, y)}{\max(\lambda_i)} * 255, i = 1, 2$ (рис. 4г, 4д);

- 5) бинаризация каждой из этих карт по порогу θ_1 и θ_2 (рис. 4е, 4ж);
- 6) нахождение пересечения $I_{1\theta}$ и $I_{2\theta} - I_R$ (рис. 4з).

Результатом приведенного выше алгоритма будет являться матрица интенсивностей, представляющая собой модифицированную карту хребтовых структур.




Рис.4. (а) – исходное изображение, (б) – стандартная эквализация гистограммы, (в) – адаптивная эквализация гистограммы, (г) – I_1 , (д) – I_2 , (е) – $I_{1\theta}$, (ж) – $I_{2\theta}$, (з) – I_R

Затем производится подсчет числа независимых связных областей, у которых хотя бы одна из точек принадлежит центральной линии позвоночника. Результат - количество найденных на изображении позвонков.

Итоговый общий вид алгоритма представлен на рисунке 5.

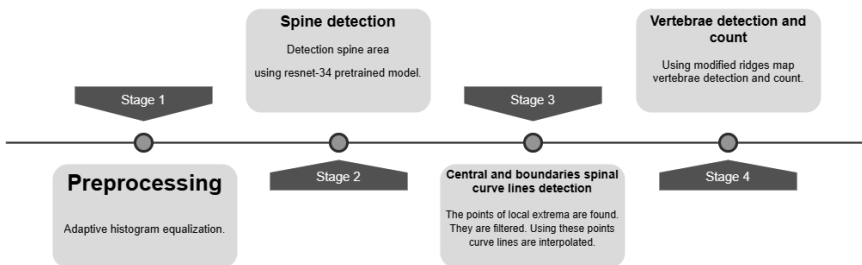



Рис.5. Общий вид алгоритма определения жесткости рентгенограмм


Отметим, что в данной работе была проведена валидация алгоритма выделения и подсчета позвонков при помощи данных экспертной разметки позвонков медицинскими экспертами. Сравнялось количество позвонков, найденных на изображении алгоритмом с количеством позвонков, обнаруженных экспертом. Для 800 изображений была посчитана разность: $r = |k_e - k_a|$, где k_e – количество позвонков, найденных экспертом, k_a – количество позвонков, найденных алгоритмом, r – ошибка алгоритма по числу позвонков. Значение r не превысило двух ($r_i \leq 2, \forall i \in [1,800]$, где i – номер изображения).

Результаты применения метода определения жесткости рентгенограмм наборов данных Montgomery, Shenzhen и выводы

Для анализа соответствия по жесткости рентгенограмм из наборов данных Montgomery и Shenzhen, - двух часто одновременно используемых для обучения и тестирования систем глубокого обучения диагностики COVID-19, были построены их гистограммы по числу позвонков на снимках.



(a)



(б)

Рис.6. (a) – гистограмма распределения числа позвонков в наборе данных Shenzhen, (б) – гистограмма распределения числа позвонков в наборе данных Montgomery

В результате, алгоритмом было выявлено различие между используемыми наборами данных по жесткости снимков (рис. 6). Снимки из набора данных Shenzhen обладали большей жесткостью, чем снимки из набора данных Montgomery, что подтверждается также визуальным анализом снимков. Также удалось выявить некачественные снимки (это снимки, на которых позвонков найти не удалось). Чаще всего это были снимки, на которых присутствовали проблемы оцифровки (рис. 7).



Рис.7. Пример некачественного снимка из набора данных Montgomery. На изображении помимо снимка легких присутствует большая неинформативная область

Детали реализации

Программная реализация предложенного метода в данной работе выполнялась на языке программирования Python 3. Для реализации моделей машинного обучения использовался фреймворк глубокого обучения pytorch 1.8.1, для работы с изображениями библиотека Pillow 8.2.0, для построения графиков использовался matplotlib. Так же использовалась библиотека scipy 1.6.3. Обучение модели производилось на Intel Core i7-9750H CPU 2.60GHz и 16 GB RAM, с графическим ускорителем NVIDIA GeForce RTX 2060 6 GB.

Заключение

В данной работе был разработан, реализован и протестирован метод автоматического определения жесткости рентгеновских снимков легких по количеству грудных позвонков. Показано, что при помощи данного метода можно успешно отделить «мягкие» снимки от «жестких» снимков. Применение данного метода в связке с нейросетевыми классификаторами должно увеличить эффективность применения последних за счет построения более однородной с точки зрения жесткости снимков обучающей выборки.

Литература

1. *Fantini I. et al.* Automatic MR image quality evaluation using a Deep CNN: A reference-free method to rate motion artifacts in neuroimaging //Computerized Medical Imaging and Graphics. – 2021. – Т. 90. – С. 101897.
2. *Zhang Q. et al.* Deep learning with attention supervision for automated motion artefact detection in quality control of cardiac T1-mapping //Artificial intelligence in medicine. – 2020. – Т. 110. – С. 101955.
3. *Nousiainen K. et al.* Automating chest radiograph imaging quality control //Physica Medica. – 2021. – Т. 83. – С. 138-145.
4. *Panicker R. O. et al.* A review of automatic methods based on image processing techniques for tuberculosis detection from microscopic sputum smear images //Journal of medical systems. – 2016. – Т. 40. – №. 1. – С. 1-13.
5. *Samuel R. D. J., Kanna B. R.* Tuberculosis (TB) detection system using deep neural networks //Neural Computing and Applications. – 2019. – Т. 31. – №. 5. – С. 1533-1545.
6. *Narin A., Kaya C., Pamuk Z.* Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks //Pattern Analysis and Applications. – 2021. – С. 1-14.

7. *Chowdhury M. E. H. et al.* Can AI help in screening viral and COVID-19 pneumonia? //IEEE Access. – 2020. – Т. 8. – С. 132665-132676.
8. *Apostolopoulos I. D., Mpesiana T. A.* Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks //Physical and Engineering Sciences in Medicine. – 2020. – Т. 43. – №. 2. – С. 635-640.
9. *Тимофеева Л. А., Алешина Т. Н., Быкова А. В.* Синдромы патологии легочной ткани. Учебное пособие – Издательство Чувашского университета, Чебоксары, 2013.
10. *Розенштраух Л.С., Виннер М.Г.* Рентгенодиагностика заболеваний органов дыхания – «Книга по Требованию», Москва, 2013.
11. *Hornig M. H. et al.* Cobb angle measurement of spine from X-ray images using convolutional neural network //Computational and mathematical methods in medicine. – 2019. – Т. 2019.
12. *Jaeger S. et al.* Two public chest X-ray datasets for computer-aided screening of pulmonary diseases //Quantitative imaging in medicine and surgery. – 2014. – Т. 4. – №. 6. – С. 475.
13. <http://archive.nlm.nih.gov/repos/chestImages.php>
14. *Subramanian V.* Deep Learning with PyTorch: A practical approach to building neural network models using PyTorch. – Packt Publishing Ltd, 2018.