

Разработка инструмента автоматизированного распознавания и устранения некорректных пикселей при выполнении томографических исследований

Н. Е. Староверов¹, Е. Д. Холопова²

Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)

¹nik0205st@mail.ru, ²wkholopova@gmail.com

Аннотация. В статье рассмотрено применение глубоких сверточных нейронных сетей архитектуры ResNet для детектирования и последующего устранения некорректных пикселей на проекционных данных микрофокусной рентгеновской томографии. Точность результатов обучения составила 91% при значении recall в 90%, что является высоким показателем. Применение предложенной сети позволяет успешно корректировать артефакты и, как следствие, повысить качество проведения томографической реконструкции.

Ключевые слова: рентгеновская томография, искусственный интеллект, сверточная нейронная сеть

I. ВВЕДЕНИЕ

Микрофокусная рентгеновская томография – это один из наиболее востребованных методов неразрушающего контроля, для реализации которого обычно используются цифровые приемники рентгеновского излучения. Для выполнения томографического исследования любых объектов требуется получить набор проекционных данных, чтобы из него при помощи математических преобразований (в классическом случае метода фильтрованных обратных проекций или итерационного алгоритма) реконструировать срезы исследуемого объекта, которые вместе с проекционными данными позволяют визуализировать трехмерный объект.

Стоит отметить, что одним из основных недостатков метода является высокий уровень шумов. Помимо этого, при проведении исследований было обнаружено, что на некоторых цифровых детекторах картина некорректных по усилению пикселей несколько меняется, что может быть связано с особенностями внутреннего устройства детекторов и передачи информации с них. В таких случаях оказывается недостаточно провести калибровку детектора, так как некорректные пиксели могут изменять свое положение в процессе сбора проекционных данных. Указанная проблема будет существенно увеличивать присутствие артефактов на полученных томографических срезах из-за наличия части «выбитых» пикселей лишь на отдельных угловых проекциях.

II. МАТЕРИАЛЫ И МЕТОДЫ

Одним из наиболее удобных способов борьбы с некорректными пикселями, меняющими свое положение, является определение данных пикселей и присвоение им значения интенсивности на основе интерполяции

соседних с ним пикселей. Например, можно использовать медианную фильтрацию, применяемую не ко всему изображению, а избирательно – к некорректным пикселям. Процедура фильтрации описывается выражением:

$$f(x, y) = \text{med}_{(s,t) \in S_{x,y}} \{g(s, t)\},$$

где $f(x, y)$ – результирующее изображение, $S_{x,y}$ – размер скользящего окна, $g(s, t)$ – яркости пикселей, находящихся в скользящем окне.

Естественно, данную операцию имеет смысл выполнять лишь для проекций с наличием некорректных пикселей. Для определения наличия некорректных пикселей на проекционных данных была применена сверточная нейронная сеть. Использование нейронной сети позволяет быстро выполнять детектирование проекций с некорректными пикселями и их обработку описанным ранее способом.



Рис. 1. Рентгеновский снимок, содержащий некорректные пиксели

Для поиска некорректных пикселей была обучена сверточная нейронная сеть архитектуры ResNet [1, 2] глубиной 50 слоев. Использование именно такой архитектуры сети обусловлено широким применением подобных сетей в задачах анализа рентгеновских изображений. Для тренировки сети использовались данные как сгенерированные искусственно (на имеющиеся наборы проекционных данных, полученных на разных детекторах с помощью опытного образца томографической системы, случайным образом добавлялись дискретные некорректные пиксели, скопления пикселей и полноценные линии), так и

полученные с различных детекторов. Всего было использовано 42534 снимка. Была применена концепция переноса обучения: использовалась сеть, обученная на наборе данных ImageNet, а при тренировке изменялись веса только полносвязного и последнего сверточного слоев. В задаче распознавания некорректных пикселей был использован стохастический градиентный спуск.

Градиентный спуск используется для минимизации функции ошибки:

$$Q(\omega) = \frac{1}{n} \sum_{i=1}^n Q_i(\omega),$$

где n – количество данных в тренировочном наборе данных.

Шаг стохастического градиентного спуска записывается, как $\omega = \omega - \eta \nabla Q_i(\omega)$, где η – это скорость обучения сети (гиперпараметр, который определяется опытным путем).

Однако его использование для оптимизации не дало удовлетворительных результатов, поэтому был использован оптимизатор Adam – adaptive moment estimation. Он сочетает в себе идею использования «момента импульса» и идею более слабого обновления весов для типичных признаков. Основная идея метода — это запоминание значения изменения параметра $\Delta\omega$ в каждой итерации и определение следующего изменения $\Delta\omega$ как разности предыдущего и полученного градиентным спуском:

$$\omega = \omega - \eta \nabla Q_i(\omega) + \alpha \Delta\omega,$$

где α – экспоненциальный коэффициент затухания между 0 и 1, определяющий относительный вклад текущего градиента и более ранние в изменении веса.

Использование подобной техники позволяет подавить сильные отклонения градиента на значительно отличающихся от большинства тренировочных примерах, повысив таким образом устойчивость алгоритма оптимизации к шуму во входных данных. В качестве функции ошибки была использована кросс-энтропия, выражение для расчета функции ошибки:

$$H(P, Q) = - \sum_x P(x) \log Q(x),$$

где P – распределение истинных ответов, а Q – распределение вероятностей прогнозов модели.



Рис. 2. Архитектура сверточной нейронной сети

Для реализации сети была использована библиотека PyTorch [3]. Сверточные нейронные сети, предварительно обученные на наборе данных ImageNet доступны во всех широко распространенных библиотеках глубокого обучения. В данной работе была выбрана библиотека PyTorch. Ввиду того, что изображения из ImageNet в большинстве своем

достаточно сильно отличаются от рентгеновских снимков, потребовалось обучать не только последний слой (классификатор), но также последний и предпоследний сверточные слои. Наилучших результатов удалось достичь, используя для обучения различных слоев отличающиеся скорости. Так, наименьшую скорость обучения имел сверточный слой, находящийся ближе всего ко входу сети, а наибольшую – линейный классификатор.

III. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

В результате большого количества экспериментов удалось определить оптимальные параметры для обучения сети. Тренировка была выполнена на графическом процессоре для сокращения времени обучения. В результате большого количества экспериментов и перебора параметров обучения по случайной сетке были определены лучшие параметры: количество эпох – 92; скорость обучения 0.00012; снижение скорости обучения в 10 раз каждые 10 эпох. Обучение производилось при помощи батчей, то есть снимков, обучающих сеть за один тренировочный проход, по 64 изображения.

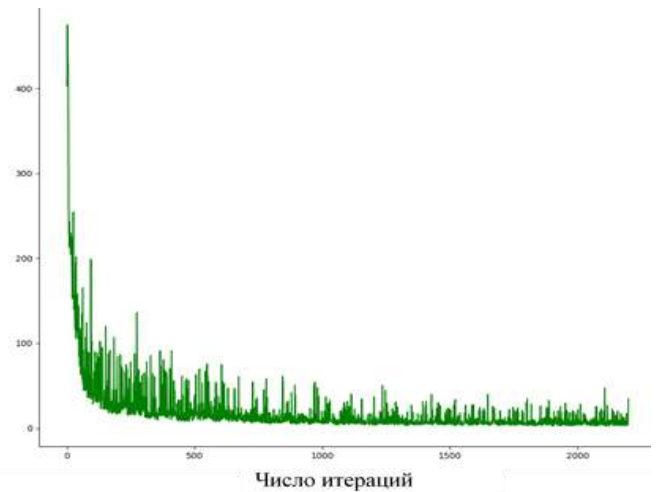


Рис. 3. Зависимость значения функции ошибки от числа итераций

Большое количество данных для обучения сети обуславливает сравнительно невысокое количество эпох обучения, поскольку было установлено, что увеличение количества эпох не приводит к повышению точности локализации области интереса на изображении из-за переобучения нейронной сети.

В ходе обучения максимизировалась метрика полнота, которая показывает долю объектов положительного класса, которые нашел алгоритм, из всех объектов положительного класса, поскольку в задачах связанных с поиском дефектов на снимках больший вес имеют пропущенные случаи, а не ложные срабатывания.

ТАБЛИЦА I РЕЗУЛЬТАТЫ РАБОТЫ МОДЕЛИ

Доля правильных ответов	Точность	Полнота	Метрика F1
0,91	0,87	0,90	0,80

Доля правильных ответов составила 91 % при значении полноты в 90 %, что является высоким показателем и говорит о применимости предложенной

нейронной сети для задачи контроля некорректных пикселей.

IV. ВЫВОДЫ

Применение предложенной сети позволяет повысить уровень коррекции артефактов и, как следствие, повысить качество проведения томографической реконструкции.

В дальнейшем планируется разработка методик повышения качества и информативности проводимых томографических исследований, путем подавления различного рода артефактов, например, таких, как кольцевые артефакты; артефакты «вне поля исследования»; артефакты движения объекта исследования.

СПИСОК ЛИТЕРАТУРЫ

- [1] Paszke A. et al. Pytorch: An imperative style, high-performance deep learning library //Advances in neural information processing systems. 2019. V. 32. Pp. 8026-8037.
- [2] He K. et al. Deep residual learning for image recognition //Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. Pp. 770-778.
- [3] Paszke A. et al. Pytorch: An imperative style, high-performance deep learning library //Advances in neural information processing systems. 2019. V. 32. Pp. 8026-8037.
- [4] Староверов Н.Е., Грязнов А.Ю., Потрахов Н.Н., Холопова Е.Д., & Гук К.К. (2018). Новые методы цифровой обработки микрофокусных рентгеновских изображений // Медицинская техника, (6), 53-55.