

Использование методов глубокого обучения для анализа эндоскопических изображений

Н. М. Шелякина¹, Г. А. Машевский²

Санкт-Петербургский государственный электротехнический университет

«ЛЭТИ» им. В. И. Ульянова (Ленина)

¹n.sheliakina@gmail.com, ²aniket@list.ru

Аннотация. Была рассмотрена проблема анализа эндоскопических изображений с помощью методов глубокого обучения. Были разработаны модели на основе сверточных нейронных сетей для диагностики воспалительных заболеваний кишечника. Полученные результаты свидетельствуют о возможности эффективного использования сверточных нейронных сетей в диагностическом процессе.

Ключевые слова: нейронные сети; глубокое обучение; болезнь Крона; язвенный колит; эндоскопические изображения

I. АКТУАЛЬНОСТЬ

Воспалительные заболевания кишечника (ВЗК) – это сложные, многофакторные заболевания, имеющие хроническое и рецидивирующее течение. К основным формам ВЗК относят болезнь Крона (БК) и язвенный колит (ЯК) [1].

Распространенность ЯК в мире составляет около 50–230 случаев на 100 тысяч населения, а ежегодный прирост – 22,3 случая на 100 тысяч населения. Распространенность БК в мире составляет около 10–200 случаев на 100 тысяч населения, а ежегодный прирост – около 10 случаев на 100 тысяч населения [2, 3]. Статистика показывает, что ВЗК имеют достаточно низкий уровень распространенности по сравнению с другими заболеваниями ЖКТ. С другой стороны, ВЗК занимают лидирующие позиции среди заболеваний ЖКТ по тяжести течения, частоте осложнений, инвалидизации населения и летальности.

Диагностика ВЗК является серьезной проблемой для современной гастроэнтерологии, ввиду неизвестных этиологии и патогенеза данных заболеваний, а также вследствие неясной причины ежегодного прироста заболеваемости. Помимо этого, в России отмечается также преобладание тяжелых форм ВЗК с высокой летальностью, что может быть связано с поздней диагностикой [4].

Таким образом, существует необходимость в разработке новых методик выявления ВЗК для своевременной и эффективной диагностики.

II. ФОРМИРОВАНИЕ ИСХОДНОГО МАССИВА

Исследование было проведено на массиве, состоящем из 900 эндоскопических изображений толстой кишки с разрешением 1350 x 1080 пикселей. Изображения в

массиве соответствуют эндоскопическим картинкам при отсутствии (класс «норма») и наличии ВЗК (класс «патология»). Класс «норма» состоит из 258 изображений, «патология» – из 642 изображений, при этом в класс «патология» входят изображения эндоскопической картины как БК, так и ЯК.

Изображения были предоставлены сотрудниками кафедры пропедевтики внутренних болезней, гастроэнтерологии и диетологии им. С. М. Рысса Северо-Западного Государственного медицинского университета имени И. И. Мечникова.

На первом этапе исследования изображения были подвергнуты предварительной обработке, поскольку ранее выполненные нами исследования показали, что данное преобразование эндоскопических изображений влияет на точность их классификации с помощью моделей глубокого обучения.

Наиболее эффективным оказалось сочетание фильтрации и улучшения контраста изображений, а также удаления зеркальных бликов с последующим закрашиванием областей. В настоящем исследовании была проведена фильтрация с использованием фильтра нелокального среднего [5], а улучшение контраста методом адаптивной контрастно-ограниченной эквализации гистограммы [6]. В алгоритме нелокального среднего значение яркости пикселя после фильтрации определяется путем усреднения значений яркостей пикселей блоков изображения, обладающих максимальной корреляцией с блоком, сформированным вокруг обрабатываемого пикселя. Метод адаптивной контрастно-ограниченной эквализации гистограммы является одной из модификаций метода эквализации гистограммы. В данном методе изображение разбивается на фрагменты, затем для каждого фрагмента формируется гистограмма и происходит перераспределение значений яркостей. При этом, в данном методе имеется ограничение гистограммы по некоторому значению, найденному перед вычислением функции распределения.

При обучении массив был разделен на обучающую и контрольную выборки в соотношении 70 %/30 %. Также изображения были приведены к размеру 256 x 256 пикселей. Пример изображения до и после предварительной обработки представлен на рис. 1.



Рис. 1. Изображение до и после предварительной обработки

Как можно видеть по рис. 1, в результате предварительной обработки зеркальные блики с изображения были успешно удалены. Также был улучшен контраст низкоконтрастных областей.

III. ОБУЧЕНИЕ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

Ввиду того, что массив изображений имеет объем, недостаточный для эффективного обучения модели с нуля, было принято решение использовать предварительно обученную нейронную сеть. Таким образом, модель для диагностики ВЗК была основана на сверточной нейронной сети VGG16 [7] и реализована с помощью открытых библиотек Keras и TensorFlow на языке программирования Python.

Используемая нами сверточная нейронная сеть VGG16, имеющая 16 слоев, была первоначально обучена на миллионах изображений из базы данных ImageNet. В процессе нашего исследования в первую очередь было необходимо адаптировать сеть под решение задачи бинарной классификации на новом массиве изображений. Для этого полносвязный слой предварительно обученной сети VGG16, т.н. «верхняя модель», был заменен небольшой моделью, состоящей из пулингового слоя, трех полносвязных слоев и слоя исключения.

Количество нейронов в полносвязных слоях было подобрано экспериментальным путем. Первый и второй полносвязные слои имеют функцию активации ReLU, 256 и 64 нейронов соответственно. Последний полносвязный слой имеет всего один выходной нейрон и сигмоидальную функцию активации. Таким образом была реализована бинарная классификация эндоскопических изображений: на выходе модель формулирует вероятность принадлежности изображения к классу 0 (класс «норма») или к классу 1 (класс «патология»).

На первом этапе была обучена только «верхняя модель»: собственные слои VGG16 не участвовали в обучении, т. е. их весовые коэффициенты не изменялись. На втором этапе модель уже полностью была обучена с использованием весовых коэффициентов, полученных на первом этапе. Иными словами, была проведена «точная настройка» сети.

Обучение «верхней модели» проводилось на протяжении 10 эпох с использованием оптимизатора Adam (адаптивная оценка момента) с шагом обучения 0,001. Для точной настройки в качестве оптимизатора был

использован стохастический градиентный спуск с шагом обучения 0,00001, а обучение проводилось на протяжении 50 эпох.

При обучении моделей была использована бинарная кросс-энтропия в качестве функции потерь и метрика «точность» для оценки обученной модели. Точность отражает долю правильно классифицированных изображений, т. е. вероятность, что класс «норма» или «патология» будет предсказан правильно.

Чтобы избежать переобучения модели на небольшом массиве изображений, была произведена аугментация данных, т.е. создание дополнительных обучающих данных из имеющихся изображений. При аугментации были случайным образом проведены следующие операции: сдвиг изображения по горизонтали и вертикали на 20 %, поворот изображения на 45 градусов, а также случайный сдвиг и увеличение изображений. Результаты обучения модели представлены в табл. 1.

ТАБЛИЦА I РЕЗУЛЬТАТЫ ОБУЧЕНИЯ МОДЕЛИ

Этапы обучения	Метрики	
	Точность	Функция потерь
Обучение верхней модели	80 %	0,5008
Точная настройка	92,22 %	0,1934

Как можно видеть по табл. 1, точная настройка позволила снизить значение функции потерь в 2,5 раза. Также наблюдается значительное увеличение точности модели.

IV. ЭКСПЕРИМЕНТАЛЬНАЯ АПРОБАЦИЯ

Далее была проведена апробация модели на массиве изображений, не участвующих в обучении. Тестирующий массив состоит из 30 изображений, 10 из которых относятся к классу «норма», 20 – к классу «патология» (по 10 изображений классов «БК» и «ЯК»). Результаты представлены в табл. 2.

ТАБЛИЦА II РЕЗУЛЬТАТЫ АПРОБАЦИИ НА ТЕСТОВОМ МАССИВЕ

Этапы обучения	Точность
Обучение верхней модели	90 %
Точная настройка	96,7 %

Т.к. точность оценивает только долю правильно классифицированных изображений и не учитывает количество ложных срабатываний модели, для оценки эффективности разработанной модели были вычислены значения чувствительности и специфичности. Чувствительность в данном случае отражает долю изображений класса «патология», верно классифицированных как таковые. Специфичность отражает долю изображений класса «норма», верно классифицированных как таковые. Результаты представлены в табл. 3.

ТАБЛИЦА III ОЦЕНКА ЧУВСТВИТЕЛЬНОСТИ И СПЕЦИФИЧНОСТИ МОДЕЛЕЙ

Этапы обучения	Критерии оценки	
	Чувствительность	Специфичность
Обучение верхней модели	90 %	90 %
Точная настройка	95 %	100 %

При тестировании модели с обученной верхней моделью одно изображение класса «норма» было неверно отнесено к классу «патология» и два изображения класса «патология» были неверно отнесены к классу «норма». При тестировании точно настроенной модели на новом массиве лишь одно изображение класса «патология» было неверно отнесено к классу «норма». Таким образом, разработанная модель выявляет наличие ВЗК с вероятностью 95 %.

V. ЗАКЛЮЧЕНИЕ

Исследование показало, что методы глубокого обучения могут быть использованы для анализа эндоскопических изображений с целью выявления воспалительных заболеваний кишечника.

Несмотря на небольшой объем исходного массива изображений, была успешно обучена модель, классифицирующая эндоскопические изображения с точностью 96,7 %, а также имеющая чувствительность и специфичность 95 % и 100 % соответственно. Следовательно, методы глубокого обучения могут быть эффективно использованы в диагностическом процессе. Также можно предположить, что описанный подход можно использовать при разработке модели для дифференциальной диагностики между болезнью Крона и язвенным колитом.

ВЫРАЖЕНИЕ БЛАГОДАРНОСТИ

Благодарим Скалинскую Марию Игоревну, доцента кафедры пропедевтики внутренних болезней, гастроэнтерологии и диетологии им. С. М. Рысса ФГБОУ

ВО СЗГМУ им. И.И. Мечникова, а также Расмагину Ирину Алексеевну, аспиранта кафедры пропедевтики внутренних болезней, гастроэнтерологии и диетологии им. С. М. Рысса ФГБОУ ВО СЗГМУ им. И.И. Мечникова, за предоставление массива эндоскопических изображений и помощь в проведении исследования.

СПИСОК ЛИТЕРАТУРЫ

- [1] Скалинская М.И., Сказываева Е.В., Бакулин И.Г., Машевский Г.А., Шелякина Н.М., Журавлева М.С., Расмагина И.А., Иванова К.Н., Формозова М.А. Проблема недифференцированных воспалительных заболеваний кишечника: от мировых воззрений до собственного опыта применения искусственных нейронных сетей // Профилактическая и клиническая медицина. 2019. № 2. С. 74-81.
- [2] Ткачев А.В., Мкртчян Л.С., Никитина К.Е., Волынская Е.И. Воспалительные заболевания кишечника: на перекрестке проблем // Практическая медицина. 2012. № 3 (58).
- [3] Князев О.В., Шкурко Т.В., Фадеева Н.А., Бакулин И.Г., Бордин Д.С. Эпидемиология хронических воспалительных заболеваний кишечника. Вчера, сегодня, завтра // Экспериментальная и клиническая гастроэнтерология. 2017. № 3 (139).
- [4] Бакулин И.Г., Авалуева Е.Б., Сказываева Е.В., Скалинская М.И., Ситкин С.И., Оганезова И.А., Назаренко И.А., Жигалова Т.Н., Бакулина Н.В., Журавлева М.С. Воспалительные заболевания кишечника. Карманное руководство // М. ООО «ГРУППА РЕМЕДИУМ». 2018. 80 С.
- [5] Buades A. (20-25 June 2005). A non-local algorithm for image denoising // Computer Vision and Pattern Recognition. 2005. No 2, pp. 60-65.
- [6] Zuiderveld K. Contrast limited adaptive histogram equalization // Graphics gems. 1994. С. 474-485.
- [7] Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition //arXiv preprint arXiv:1409.1556. 2014.