

ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ДАННЫХ О ДИАБЕТИЧЕСКОЙ РЕТИНОПАТИИ НА СНИМКАХ С НИЗКОЙ СТЕПЕНЬЮ ДОВЕРИЯ

И.С. Ванюшин, К.Р. Марупова
Научный руководитель – к. т. н., доцент Фофанов О. Б.
Томский политехнический университет
iwdnot@gmail.com

Диабетическая ретинопатия — одно из наиболее тяжёлых осложнений сахарного диабета проявление диабетической микроангиопатии, поражающее сосуды сетчатой оболочки глазного яблока, наблюдаемое у 90% пациентов при сахарном диабете. [1]. По расчетам специалистов количество людей, болеющих сахарным диабетом, к 2025 году может достигнуть критической отметки — 300 миллионов человек [2].

Одним из важнейших элементов работы с моделями является процесс подбора данных для модели – поиск уже готового набора данных, либо же создание своего собственного. Характер данных в поставленной задаче таков, что составлять свой датасет не представляется возможным – данные крайне специфичны и должны составляться с помощью специалиста, обладающим экспертным знанием в предметной области. Поэтому было принято решение воспользоваться уже готовым набором данных, состоящий из 90 000 изображений, 57 гигабайт снимков высокого разрешения. Все изображения были размечены специалистами высокого класса с методом перекрестной проверки результатов.

На первом этапе, все изображения были уменьшены до единого разрешения 384*384. Данные изображения будут использоваться как, единичные наборы данных, на основе которых будут формироваться прогнозные признаки. Такой подход позволит: (1) снизить количество данных на каждом образце без потери качества генерируемых признаков; и (2) стандартизировать подаваемые на вход к модели изображения.

Для улучшения качества изображения к ним было применено адаптивное усреднение гистограммы с ограничением по контрастности (CLAHE). Его основное отличие от обычного выравнивания гистограммы в вычислении группы гистограмм, каждая из которых соответствует отдельной части изображения, и использует их для перераспределения значений яркости изображения. Данный фактор помог выделить артефакты и сосуды на изображениях, увеличив качество модели за счет более полных данных.

Практические исследования, опрос экспертов и изучение научной литературы показали большую значимость контуров сосудов глазного дна. [3-4] В связи с этим было принято решение обучить дополнительно сегментатор сосудов и использовать его результаты для прогнозирования.

Классический подход сегментации подразумевает обучение энкодера/декодера на открытых наборах данных (датасетах) DRIVE и STARE, ставшими стандартными в данной задаче. Для этого снимки высокого разрешения из этих датасетов делаются на небольшие изображения, и сегментаторы на них обучаются выделять сосуды с изображения. Этот подход показал себя крайне эффективным, но в настоящее время был сформулирован и другой подход, результаты которого превосходят классический подход.

Этот подход основан на формировании GAN-модели самих изображений сосудов. Генеративно-состязательная сеть (GAN) — алгоритм машинного обучения без учителя, построенный на комбинации из двух нейронных сетей, одна из которых (сеть G) генерирует образцы, другая (сеть D) — старается отличить правильные («подлинные») образцы от неправильных [5]. Так как сети G и D имеют противоположные цели — создать образцы и отбраковать образцы — между ними возникает антагонистическая игра. Подобная архитектура будет использоваться для имитации изображений сосудов глаза, подавая на вход исходное изображение. Таким образом задача сводится к «обману» дискриминатора D, путем обучения генеративной модели G созданию картины сегментации, неотличимой от настоящих для дискриминатора D.

Для обучения модели были подобраны различные архитектуры CNN, предназначенные для распознавания образов и классификации изображений. В частности, среди рассматриваемых архитектур моделей были ResNet-50 [6] и Inception V3, а также сочетание ключевых принципов этих двух моделей – Inception-ResNet V2 [7]. Принципиальные различия блоков ResNet и Inception архитектур представлены ниже. Более глубокие архитектуры сетей зарекомендовали себя в данной задаче как более эффективные, это объясняется трудной семантикой задачи, где признаки, характеризующие описываемое изображения, представляют из себя очень сложные взаимосвязи в исходных данных.

Было определено: синий канал изображений глаз практически не представляет никакой значимости для конечного результата. На обученных моделях проведено тестирование исходных изображений и изображений с синим каналом, сгенерированными случайно и замененными. В результате преобразований целевые метрики не изменились.

Данный фактор обеспечил возможность заменять входной синий канал изображения сегментированными сосудами, важными для прогнозирования. Ранее сегментированные сосуды подсоединялись четвертым каналом для изображений. Теперь для обучения модели с тремя каналами появилась возможность использовать предобученные веса других моделей для увеличения скорости сходимости модели.

Для оценки качества классификатора использовалась стандартная метрика ROC AUC. Площадь под ROC-кривой (AUC) является агрегированной характеристикой качества классификации, не зависящей от соотношения цен ошибок. Чем больше значение AUC, тем «лучше» модель классификации. Данный показатель часто используется для сравнительного анализа нескольких моделей классификации.

Заключение

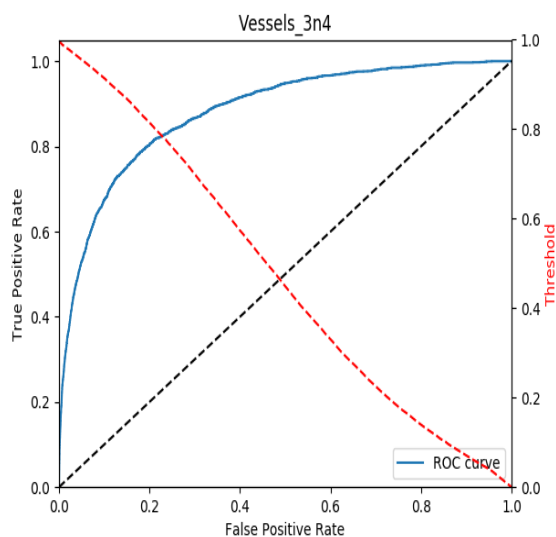


Рис. 1. Классификатор 0 класс vs 3&4 класс, AUC = 0.88

В результате выполнения настоящей исследовательской работы были исследованы различные возможности сверточных нейронных сетей в задаче

обработки изображений дна человеческого глаза для определения клинической картины пациента с диабетом. Были предложены различные подходы и архитектуры моделей, а также протестированы способы сочетания последних исследований по части сегментации сосудов для улучшения результатов работы модели. Основная часть работы была проделана при помощи фреймворка для создания нейронных сетей Pytorch и библиотеки обработки изображений OpenCV, обе библиотеки представлены в виде пакетов для языка Python.

Список использованных источников

1. Касаткина Э. П. Сахарный диабет у детей. — 1-е изд. — М.: Медицина, 1990. — С. 206—207. — 272 с. — 60 000 экз. — ISBN 5-225-01165-9.
2. Крысанов И. С. Фармакоэкономика сахарного диабета // Фармакоэкономика. Современная фармакоэкономика и фармакоэпидемиология. — 2009. — №. 1
3. Niemeijer M. et al. Comparative study of retinal vessel segmentation methods on a new publicly available database //Medical-Imaging 2004: Image Processing. — International Society for Optics and Photonics, 2004. — Т. 5370. — с. 648-657.
4. Ravishankar S., Jain A., Mittal A. Automated feature extraction for early detection of diabetic retinopathy in fundus images //Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on. — IEEE, 2009. — С. 210-217.
5. Goodfellow I. et al. Generative adversarial nets //Advances in neural information processing systems. — 2014. — С. 2672-2680.
6. He K. et al. Deep residual learning for image recognition //Proceedings of the IEEE conference on computer vision and pattern recognition. — 2016. — с. 770-778.
7. Szegedy C. et al. Inception-v4, inception-resnet and the impact of residual connections on learning //AAAI. — 2017. — Т. 4. — С. 12.