

А. Ф. Смалюк

Институт бизнеса БГУ, Минск, Беларусь, asmaliuk@gmail.com

ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ АНАЛИЗА ДЕРМАТОСКОПИЧЕСКИХ ИЗОБРАЖЕНИЙ

В работе рассмотрены ряд задач анализа дерматоскопических изображений, в первую очередь задачи классификации и сегментации. Изучен ряд архитектур нейронных систем и их применимость для решения этих задач для анализа дерматоскопических изображений новообразований кожи. Описаны требования, предъявляемые различными архитектурами нейронными сетями к обучающим данным и некоторые перспективные направления для дальнейших исследований в данной области.

Ключевые слова: *нейронные сети, меланома, дерматоскопические изображения, классификация, сегментация*

A. Smaliuk

School of Business of BSU, Minsk, Belarus, asmaliuk@gmail.com

USING NEURAL NETWORKS IN DERMATOSCOPIC IMAGE ANALYSIS

The paper examines a number of problems in the analysis of dermoscopic images, primarily the problems of classification and segmentation. A number of neural system architectures and their applicability to solving these problems for the analysis of dermoscopic images of skin tumors are considered. The requirements imposed by various neural network architectures on training data are considered. Some directions for further research in this area are shown.

Keywords: *neural networks, melanoma, dermoscopic images, classification, segmentation*

Одними из самых опасных новообразований кожи является меланома — агрессивная форма рака кожи, которая развивается, как правило, из пигментных клеток. В Беларуси наблюдается стабильный рост уровня заболеваемости этой формой рака кожи. Для успешного лечения меланомы кожи важнейшим фактором является ранняя диагностика заболевания. При этом для постановки правильного диагноза, как правило, требуется достаточно высокая квалификация врача. Существующие методики постановки диагноза основываются на наборах критериев, таких, например, как ABCDE — самый известный на данный момент [1]. Но они не всегда являются эффективными и требуют высокой квалификации врача. Связано это в первую очередь с тем, что на ранних стадиях, когда лечение будет наиболее эффективным, меланомы могут несущественно отличаться от доброкачественных невусов (родинок) (см. рис. 1).




Рис. 1. Дерматоскопическое изображение меланомы и невуса (справа).

При этом у многих групп населения, особенно у проживающих вдали от крупных населенных пунктов, доступ к высококвалифицированному специалисту оказывается затрудненным. В связи с этим чрезвычайно важным является разработка автоматизированных компьютерных систем, которые могут на основе дерматоскопических изображений кожи поставить предварительный диагноз без непосредственного участия врача.

Существующие системы обычно используют два подхода – анализ изображения по тем же критериям, что применяются врачами – неравномерность окраски, неправильность формы новообразования и т. д., либо задействуют нейронные сети или другие инструменты искусственного интеллекта для определения типа новообразования.

При любом из этих двух подходов важной является задача сегментации изображения, в ходе которой из общего дерматоскопического изображения выделяется область самого новообразования, например, как показано на рис. 2.




Рис. 2. Исходное и сегментированное изображение (справа)

При первом подходе сегментация позволяет анализировать форму новообразования и другие его характеристики, не затрагивая окружающую кожу, при использовании второго подхода предварительная сегментация изображения (а также изображений в обучающих наборах), как правило, повышает точность результата, выдаваемого нейронной сетью.

Для постановки диагноза с использованием нейронных сетей решается задача так называемой классификации изображений, в ходе которой сеть получает на вход проверяемое изображение и выдает на выход вероятности того, что изображение относится к одному из видов новообразований. В самом простом случае это могут быть две категории: меланома и не меланома. В более сложных случаях сеть определяет конкретный тип новообразований: меланома, невус, кератома, базилиома и т. д.

Простые нейронные сети прямого распространения

Попытки использования нейронных сетей для классификации изображений начались фактически с началом исследования нейронных сетей как таковых. Но архитектура первоначальных нейронных сетей так называемой перцептронов, представлявших собой несколько слоев обычных элементов, симулирующих нейроны, имела существенные ограничения. Каждая точка анализируемого изображения соответствует как минимум одному элементу входного слоя. Это означает, что даже для небольшого изображения 100 на 100 точек входной слой состоит из 10 000 элементов, и если последующий слой состоит хотя бы из 1 000 нейронов, это сразу дает 10 млн параметров для вычисления. Это значительно ограничивает возможности такой архитектуры для задач классификации изображений.

Кроме того, в таких нейронных сетях увеличение количества слоев, необходимое для решения сложных задач классификации, существенно усложняет процесс обучения. Из-за того, что для выявления многих признаков злокачественных новообразований необходимо

использовать снимки в высоком разрешении, использование простых нейронных сетей прямого распространения для данных задач является практически невозможным.

Сверточные нейронные сети

Качественный скачок в задачах анализа изображений произошел при появлении сверточных нейронных сетей. Сети данного типа были предложены в 1989 г. [2], и первой практической задачей для них являлось распознавание цифр почтовых индексов, записанных от руки. Использование сверточных слоев позволяет создавать сети значительно большей глубины и, как следствие, значительно улучшить точность получаемых результатов при классификации изображений. Важными шагами в развитии сверточных нейронных сетей стали сети LeNet [3] и AlexNet [4], созданные в 1998 и 2012 гг. соответственно. Эти сети на практике продемонстрировали преимущества сверточных нейронных сетей и применимость их к реальным задачам. Так, использующие данную архитектуру нейронные сети семейства VGG, предложенные в 2015 году, позволили получить уровень ошибки менее 10 % на наборе изображений ImageNet, включающем 15 млн изображений в 15 тыс. категорий, который около десяти лет был главным инструментом для исследований задачи классификации изображений.

На этом этапе сверточные нейронные сети начали использоваться для классификации дерматоскопических изображений. В сети появился набор изображений новообразований кожи ISIC, который включал тысячи дерматоскопических снимков новообразований кожи и был создан связанный с ним конкурс ISIC 2016 по получению наилучших результатов классификации снимков с использованием данного набора как обучающего. Далее каждый год до 2020 конкурс повторялся.

В первый год существования этого конкурса первое место заняла сверточная нейронная сеть, имевшая среднюю точность диагноза 0.64. В последующие годы с применением новых архитектур точность существенно возросла.

С появлением VGG стали понятны ограничения, которые имеют сверточные нейронные сети прямого распространения. Самой большой сетью данного семейства стала сеть VGG-19, включающая в себя 19 слоев нейронов. Уже на этой глубине возникают проблемы со скоростью обучения, и такие сети требуют значительных аппаратных ресурсов для обучения.

Главной проблемой сетей с большим количеством слоев вообще и сетей прямого распространения в особенности стала проблема исчезающего градиента, когда в ходе обучения, величины градиента коэффициентов становятся такими маленькими, что обучение сети становится неоправданно долгим или вообще прекращается.

Для решения этих проблем в сверточных нейронных сетях были предложены ряд модификаций. Одной из самых распространенных и используемых по сей день является сеть с т. н. residual блоками. Главной идеей таких блоков является добавление дополнительных связей, называемых пропускными соединениями (skip connections). Данные связи передают информацию из начала блока в конец, где она соединяется с результатами работы сверточных слоев, находящихся в блоке (см. рисунок 3). Семейство нейронных сетей, использующих такие блоки получило название ResNet [5]. Наличие пропускных соединений существенно уменьшает вероятность возникновения исчезающего градиента, и как следствие позволяет создавать и успешно обучать более глубокие сети. Поэтому подобные элементы в настоящее время используются в большинстве популярных архитектур нейронных сетей.




Рис. 3. Пример блока с пропускным соединением

В сверточных нейронных сетях разный размер ядра свертки позволяет сети обнаруживать на изображениях признаки разного размера, при этом последовательное расположение множества слоев разного размера увеличивает глубину сети и как следствие, ухудшает обучаемость. Поэтому сотрудниками компании Google была предложена новая модификация нейронных сетей, получившая название Inception. Главной ее особенностью является то, что в блоках этой сети несколько сверточных слоев с различным размером ядер располагаются не последовательно, а параллельно (рис. 4), что уменьшает вероятность появления исчезающего градиента и улучшает обучаемость сети.




Рис. 4. Пример блока сети Inception

Большая часть нейронных сетей, предлагаемых в настоящее время для диагностики злокачественных образований кожи по дерматоскопическим изображениям, основано на описанных выше принципах.

Сегментация дерматоскопических изображений

Как уже было сказано ранее, предварительная сегментация исследуемых изображений позволяет значительно повысить точность результатов, получаемых с помощью нейронных сетей.

Самым простым и широко распространенным методом сегментации изображений является пороговая обработка, с получением значения порога либо с участием человека, либо с одним из автоматизированных методов, например методом Оцу [6]. Но для дерматоскопических изображений пороговая обработка не всегда применима, из-за наличия на снимках артефактов оптики, волос, неравномерной окраски самих новообразований.

Значительно лучшие результаты дает использование нейронных сетей, и в частности сетей архитектуры U-net, которая впервые была предложена в 2015 году Роненнбергом, Фишером и Броксом для сегментации клеток на микроскопических снимках [7]. Структура данной сети показана на рис. 5.




Рис. 5. Структура сети U-net.

Данная архитектура и ее производные, такие как U-net с механизмом внимания [8], позволяют автоматизировать сегментацию дерматоскопических снимков с точностью, превышающей 0.95. При этом важным достоинством данной архитектуры являются невысокие требования к объему обучающей выборки данных, для получения хорошей точности достаточно нескольких сотен изображений.

Автор успешно использовал данную архитектуру для подготовки обучающих наборов данных для сверточных нейронных сетей, выполняющих классификацию изображений [9]. В процессе обучения данная архитектура продемонстрировала точность до 0.9767.

Перспективные направления исследований

В настоящее время активно идут исследования применения нейронных сетей типа Transformer, имеющих в своей основе механизм внимания для сегментации и классификации изображений. Данная архитектура лежит в основе таких известных продуктов как GPT-3 и GPT-4 и изначально разрабатывалась для обработки текста [10], но она оказалась достаточно универсальной, чтобы ее вариации нашли применение в обработке изображений.

При этом ряд ее особенностей может ограничивать успешность применения данной архитектуры. Так, наилучшие результаты получаются при обучении таких нейронных сетей, если набор обучающих данных имеет очень большой объем (миллионы изображений), на меньших объемах результаты могут соответствовать или быть даже несколько хуже результатов современных сверточных сетей. А учитывая, что самые большие базы данных дерматоскопических изображений включают десятки тысяч снимков, эффективность данных архитектур для диагностики новообразований кожи остается под вопросом.

Список использованных источников

1. Clinical ABCDE rule for early melanoma detection / A.F. Duarte [et al.] // Eur J Dermatol. – 2021. – Vol. 31(6). – P. 771–778.
3. Backpropagation Applied to Handwritten Zip Code Recognition // Y. LeCun [et al.] Neural Computation. – 1989. – Vol. 1(4). – P. 541–551.
4. Gradient-based learning applied to document recognition / Y. Lecun [et al.] // Proceedings of the IEEE. – 1998. – Vol. 86 (11). – P. 2278–2324.
5. Krizhevsky, Alex. ImageNet classification with deep convolutional neural networks / Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton // Communications of the ACM. – 2012. – Vol. 60 (6). – P. 84–90.
6. Deep residual learning for image recognition/ K. He [et al.]// Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – C. 770–778.

7. A threshold selection method from gray-level histograms/ N. Otsu [et al.]// Automatica. – 1975. – Т. 11. – №. 285-296. – С. 23-27.
8. *Ronneberger, O.* U-net: Convolutional networks for biomedical image segmentation/ O. Ronneberger, P. Fischer, T. Brox // Medical image computing and computer-assisted intervention–MICCAI 2015 : 18th international conference, Munich, Germany, October 5–9, 2015, proceedings, part III 18. – Springer International Publishing, 2015. – С. 234–241.
9. Attention u-net: Learning where to look for the pancreas / O. Oktay [et al.]// arXiv preprint arXiv:1804.03999. – 2018.
10. *Смалюк, А. Ф.* Сегментация дерматоскопических изображений новообразований кожи. Сравнение методик / А. Ф. Смалюк, М. С. Дешко, И. Д. Купчикова // Системный анализ и прикладная информатика. – 2024. – № 1. – С. 60–68.
11. Attention is all you need / A. Vaswani [et al.] // Advances in neural information processing systems : 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA. – 2017. – 15 p.