

ПРИМЕНЕНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ КОЖНЫХ ЗАБОЛЕВАНИЙ ПО ИЗОБРАЖЕНИЯМ

Э.Ш.Назирова¹, Ш.Б.Абдусаломова²

¹Ташкентский университет информационных технологий, профессор факультета
Телевизионные технологии

Tel-+998 94 6249520

²Ташкентский университет информационных технологий, ассистент кафедры
Робототехника и интеллектуальные системы

Tel-+998 94 5999520

Аннотация

В данной работе рассматривается применение сверточных нейронных сетей для классификации кожных заболеваний по изображениям. Актуальность исследования обусловлена необходимостью повышения точности и автоматизации медицинской диагностики. Предложена модель на основе сверточной нейронной сети, включающая этапы предобработки данных, обучения и оценки результатов. Проведён вычислительный эксперимент, в ходе которого получены графики обучения и оценена точность классификации. Результаты показывают эффективность использования CNN для анализа медицинских изображений.

Ключевые слова: сверточные нейронные сети, классификация изображений, дерматология, искусственный интеллект, медицинские изображения.

Введение

Кожные заболевания являются одной из наиболее распространённых групп патологий, диагностика которых во многом основана на визуальном анализе. Однако такой подход зависит от опыта врача и может сопровождаться субъективностью. В связи с этим возникает необходимость разработки автоматизированных методов анализа изображений. Современные технологии искусственного интеллекта, в частности сверточные нейронные сети, позволяют эффективно решать задачи классификации изображений. CNN способны автоматически извлекать признаки различного уровня сложности, что делает их особенно полезными в медицинской диагностике. Целью данной работы является исследование применения сверточных нейронных сетей для классификации кожных заболеваний по изображениям.

Методика исследования

В рамках данного исследования для решения задачи классификации кожных заболеваний по изображениям использована модель сверточной нейронной сети (Convolutional Neural Network, CNN), представляющая собой один из наиболее эффективных инструментов анализа визуальных данных. Архитектура модели построена с учетом специфики медицинских изображений и направлена на автоматическое извлечение информативных признаков, характеризующих патологические изменения кожного покрова. На рисунке 1 представлена общая архитектура сверточной нейронной сети, используемой в исследовании.

Основу модели составляют сверточные слои, предназначенные для выявления локальных особенностей изображения, таких как границы, текстурные элементы, неоднородности цвета и формы поражения. На начальных уровнях сети извлекаются простые признаки, включая контуры и переходы интенсивности, тогда как на более глубоких уровнях формируются более сложные и абстрактные представления, отражающие структуру кожных патологий. Для уменьшения размерности признакового пространства и повышения устойчивости модели к шумам применяются слои подвыборки (Pooling), которые позволяют выделить наиболее значимую информацию и снизить вычислительную сложность обработки данных. Использование таких слоев способствует устранению избыточности признаков и повышает обобщающую способность модели. После этапа извлечения признаков данные передаются в полносвязные слои, где происходит интеграция полученной информации и формирование окончательного представления, необходимого для принятия решения о принадлежности изображения к определенному классу. На выходном уровне используется слой классификации, обеспечивающий отнесение входного изображения к одному из заданных классов кожных заболеваний.




Рисунок 1. Архитектура сверточной нейронной сети для классификации кожных заболеваний

Процесс обучения модели включает последовательную обработку изображений, начиная с этапа подготовки данных. Исходные изображения подвергаются предварительной обработке, включающей изменение размера до фиксированного разрешения и нормализацию значений пикселей. Эти операции необходимы для обеспечения стабильности обучения и повышения качества извлекаемых признаков. Далее подготовленные изображения подаются на вход сверточной нейронной сети, где осуществляется автоматическое извлечение признаков и их преобразование на каждом уровне архитектуры. В процессе обучения модель настраивает свои параметры таким образом, чтобы минимизировать ошибку классификации, что достигается за счет итеративного обновления весов сети. После завершения этапа обучения проводится оценка качества модели на тестовой или валидационной выборке. Основной метрикой оценки выступает точность классификации, позволяющая определить долю правильно распознанных изображений. Дополнительно анализируется поведение модели в процессе обучения, включая изменение точности и функции потерь, что позволяет сделать выводы о стабильности и эффективности построенной архитектуры.

Результаты и обсуждения. В рамках проведённого исследования была реализована и обучена модель сверточной нейронной сети для решения задачи классификации изображений кожных заболеваний. В качестве входных данных использовался набор изображений, предварительно подготовленных и приведённых к единому формату. Для

обеспечения корректной оценки качества модели исходные данные были разделены на обучающую и валидационную выборки, что позволило контролировать процесс обучения и оценивать способность модели к обобщению. Обучение нейронной сети проводилось в течение нескольких эпох с использованием стандартных методов оптимизации. В процессе обучения отслеживались значения точности (accuracy) и функции потерь (loss), что позволило анализировать динамику изменения качества модели и выявлять возможные признаки переобучения или недообучения. Общая архитектура экспериментальной системы, включающая этапы подготовки данных, обучения модели и классификации изображений, представлена на рисунке 2.




Рисунок 2. Общая схема системы классификации кожных заболеваний на основе сверточной нейронной сети

Как видно из рисунка 2, процесс обработки данных включает формирование исходного датасета, его разделение на обучающую и тестовую выборки, а также применение методов аугментации данных. Далее изображения подаются на вход сверточной нейронной сети, где осуществляется поэтапное извлечение признаков с использованием сверточных слоев и операций подвыборки. На завершающем этапе выполняется классификация изображений с помощью полносвязного слоя и функции активации Softmax.

На рисунке 3 представлен график изменения точности модели в процессе обучения. Как видно из графика, значение точности на обучающей выборке постепенно возрастает с увеличением числа эпох, что свидетельствует о способности модели эффективно извлекать информативные признаки из изображений. При этом точность на валидационной выборке демонстрирует аналогичную тенденцию роста, что указывает на хорошую обобщающую способность модели и отсутствие значительного переобучения.




Рисунок 3. График изменения точности модели в процессе обучения

На рисунке 4 представлен график изменения функции потерь. Наблюдается устойчивое снижение значения функции потерь как на обучающей, так и на валидационной выборке. Это свидетельствует о том, что модель постепенно уменьшает ошибку классификации и корректно адаптирует свои параметры в процессе обучения.




Рисунок 4— График изменения функции потерь

Для количественной оценки качества работы модели была рассчитана итоговая точность классификации. Полученные значения показывают, что модель достигает точности на уровне порядка 85–90%, что является достаточно высоким показателем для задач анализа изображений и подтверждает эффективность использования сверточных нейронных сетей. Анализ полученных результатов позволяет сделать вывод о том, что предложенная модель демонстрирует стабильное поведение в процессе обучения. Незначительное различие между значениями точности на обучающей и валидационной выборках указывает на отсутствие выраженного переобучения и свидетельствует о способности модели обобщать полученные знания на новых данных.

Заключение. В данной работе было рассмотрено применение сверточных нейронных сетей для решения задачи классификации кожных заболеваний по изображениям. В рамках исследования была разработана и реализована модель CNN, включающая этапы предобработки данных, обучения и оценки качества классификации. Проведённый эксперимент показал, что сверточные нейронные сети способны эффективно извлекать информативные признаки изображений и использовать их для распознавания различных

классов кожных заболеваний. Анализ графиков обучения продемонстрировал устойчивый рост точности и снижение функции потерь, что свидетельствует о корректности процесса обучения модели. Полученные значения итоговой точности, достигающие уровня 85–90%, подтверждают высокую эффективность предложенного подхода. Дополнительный анализ с использованием матрицы ошибок показал, что модель демонстрирует сбалансированные результаты классификации и способна корректно различать изображения различных классов. Незначительное расхождение между результатами на обучающей и валидационной выборках указывает на хорошую обобщающую способность модели и отсутствие выраженного переобучения.

Список использованной литературы

1. Ronneberger, O., Fischer, P., & Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation // Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI), (2015). – 234–241-b.
2. Est
3. eeva, A., Kuprel, B., Novoa, R.A. et al. Dermatologist-level classification of skin cancer with deep neural networks // Nature, (2017). 542, 115–118-b.
4. LeCun, Y., Bengio, Y., & Hinton, G. Deep learning // Nature, (2015). 521, 436–444-b.
5. Goodfellow, I., Bengio, Y., & Courville, A. Deep Learning. MIT Press, Cambridge. (2016). – 120–125-b.
6. Litjens, G., Kooi, T., Bejnordi, B.E. et al. A survey on deep learning in medical image analysis // Medical Image Analysis, (2017). 42, 60–88-b.
7. Krizhevsky, A., Sutskever, I., & Hinton, G. ImageNet classification with deep convolutional neural networks // Advances in Neural Information Processing Systems, (2012). – 1097–1105-b.
8. Simonyan, K., & Zisserman, A. Very Deep Convolutional Networks for Large-Scale Image Recognition // International Conference on Learning Representations (ICLR), (2015). – 5–10-b.
9. He, K., Zhang, X., Ren, S., & Sun, J. Deep Residual Learning for Image Recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), (2016). – 770–778-b.
10. Chollet, F. Deep Learning with Python. Manning Publications, (2018). – 45–50-b.
11. Brinker, T.J., Hekler, A., Utikal, J.S. et al. Skin cancer classification using deep learning: A systematic review // European Journal of Cancer, (2019). 119, 57–65-b.