

ИСПОЛЬЗОВАНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ (CNN) ДЛЯ ВЫЯВЛЕНИЯ ПАТОЛОГИЙ ЛЕГКИХ НА РЕНТГЕНОВСКИХ ИЗОБРАЖЕНИЯХ

Сафарова Г.Т

(Самаркандский филиал ТУИТ)

Заболевания легких, включая пневмонию, туберкулез и рак легких, представляют собой значительную угрозу для общественного здравоохранения по всему миру. Традиционные методы диагностики, основанные на визуальной интерпретации рентгеновских снимков специалистами, могут быть трудоемкими и подвержены ошибкам. В последние годы применение сверточных нейронных сетей (CNN) для анализа медицинских изображений демонстрирует обещающие результаты, предлагая автоматизированный и высокоточный подход к диагностике. В данной статье рассматривается применение CNN к диагностике заболеваний легких, обзор текущего состояния исследований в этой области, а также обсуждаются потенциальные преимущества.

Ранняя диагностика играет критическую роль в успешном лечении и снижении смертности. Рентгеновские снимки грудной клетки остаются доступным и широко используемым методом для первичной диагностики заболеваний легких. Однако точность диагностики сильно зависит от опыта и квалификации радиологов [1]. Сверточные нейронные сети, благодаря своей способности к обучению на больших объемах данных и выявлению сложных визуальных паттернов, представляют собой мощный инструмент для улучшения диагностики на основе рентгеновских снимков.

СБОР И ПОДГОТОВКА ДАННЫХ

Первым шагом в применении CNN к диагностике заболеваний легких является сбор и подготовка обширного набора рентгеновских снимков. Эти данные должны быть тщательно аннотированы медицинскими экспертами, чтобы обеспечить точные метки для обучения и тестирования модели.

Сбор данных начинается с получения обширного набора рентгеновских снимков легких. Важно, чтобы собранный датасет был разнообразным и представлял широкий спектр заболеваний легких, включая пневмонию, туберкулез, рак легких и другие состояния. Разнообразие помогает в обучении более универсальных и точных моделей CNN, способных распознавать различные патологии [2, 3].

После сбора снимков необходима их тщательная аннотация медицинскими экспертами. Аннотация включает в себя не только классификацию заболеваний, но и, при возможности, указание на локализацию патологических областей на снимках.

Для оценки производительности модели данные делится на три подмножества: обучающее, валидационное и тестовое. Обучающий набор используется для тренировки CNN, валидационный — для настройки гиперпараметров и оценки промежуточной производительности в процессе обучения, а тестовый набор предназначен для окончательной оценки производительности модели.

АРХИТЕКТУРА CNN

Выбор архитектуры сверточной нейронной сети (CNN) играет решающую роль в обеспечении высокой точности диагностики заболеваний легких на основе рентгеновских снимков [4]. Современные исследования подчеркивают, что использование глубоких архитектур CNN, таких как ResNet, Inception и DenseNet, обеспечивает значительные преимущества за счет их способности извлекать сложные признаки из медицинских изображений. Рассмотрим ключевые аспекты этих архитектур и их применение в медицинской диагностике.

ResNet представляет собой революционный подход к построению глубоких нейронных сетей, вводя так называемые "остаточные блоки", которые позволяют сигналам пропускать один или несколько слоев. Это существенно уменьшает проблему исчезающего градиента, позволяя обучать сети с глубиной в сотни и даже тысячи слоев. ResNet может эффективно обрабатывать рентгеновские снимки для выявления и классификации различных патологий благодаря своей способности к глубокому изучению признаков.

Архитектура Inception, в особенности ее вариант Inception-v3, предлагает сложную структуру, состоящую из модулей, в которых параллельно выполняются свертки разного размера, а результаты затем объединяются. Это позволяет сети адаптироваться к признакам различного масштаба и эффективно использовать вычислительные ресурсы. Такая архитектура особенно подходит для обработки медицинских изображений, где важно распознавать патологии разного размера и формы.

DenseNet улучшает передачу признаков между слоями за счет того, что каждый слой получает на вход признаки от всех предыдущих слоев. Это обеспечивает более эффективное использование признаков и уменьшает количество параметров, необходимых для обучения [4]. В

контексте диагностики заболеваний легких, DenseNet может эффективно обрабатывать сложные зависимости между различными областями изображения, выявляя даже незначительные изменения, указывающие на наличие заболевания.

ОБУЧЕНИЕ И ВАЛИДАЦИЯ МОДЕЛИ

Обучение CNN требует использования передовых алгоритмов оптимизации и техник регуляризации для предотвращения переобучения. Валидация модели на независимом тестовом наборе данных позволяет оценить ее способность к обобщению и точности диагностики.

Обучение модели. Современные алгоритмы оптимизации, такие как Adam, RMSprop или SGD с импульсом, используются для обновления весов нейронной сети в процессе обучения. Эти алгоритмы помогают ускорить сходимость обучения и улучшить общую производительность модели. Для борьбы с переобучением применяются различные методы регуляризации, включая Dropout, L1 и L2 регуляризации. Dropout временно исключает часть нейронов из обучения, что делает модель менее чувствительной к шуму в данных. L1 и L2 регуляризации ограничивают величину весов, способствуя созданию более простых и стабильных моделей.

Использование моделей, предварительно обученных на больших наборах данных (таких как ImageNet), может значительно ускорить процесс обучения и улучшить качество диагностики, особенно когда доступное количество медицинских изображений ограничено [3].

Валидация модели. Для объективной оценки производительности модели используется независимый тестовый набор данных, который не участвовал в процессе обучения. Это позволяет оценить способность модели к обобщению на новых данных. Кросс-валидация, особенно метод k-кратной кросс-валидации, позволяет более надежно оценить производительность модели, разделяя данные на несколько подмножеств и последовательно используя каждое из них в качестве тестового набора. Применяются различные метрики оценки, включая точность (accuracy), чувствительность (sensitivity), специфичность (specificity) и площадь под кривой ошибок (AUC ROC), для комплексной оценки качества диагностики модели.

ПРЕИМУЩЕСТВА ИСПОЛЬЗОВАНИЯ CNN

- Улучшение точности диагностики: Автоматизация процесса анализа рентгеновских снимков может снизить человеческий фактор и повысить точность диагностики.

- Сокращение времени диагностики: CNN могут анализировать изображения значительно быстрее, чем это делают специалисты, что особенно важно в условиях высокой нагрузки на медицинские учреждения.

- Доступность: Автоматизированная система диагностики может быть особенно полезна в регионах с ограниченным доступом к квалифицированным радиологам.

Применение CNN к диагностике заболеваний легких на основе рентгеновских снимков представляет собой многообещающее направление, которое может радикально трансформировать подходы к диагностике и лечению. Несмотря на существующие вызовы, продолжающиеся исследования и разработки в этой области открывают новые горизонты для повышения качества и доступности медицинской помощи.

СПИСОК ЛИТЕРАТУР:

1. Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., Shpanskaya, K., Lungren, M.P., Ng, A.Y. (2017). "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning." arXiv:1711.05225 [cs.CV].

2. Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., Summers, R.M. (2017). "ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), стр. 3462-3471.

3. Lakhani, P., Sundaram, B. (2017). "Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural Networks." Radiology, 284(2), стр. 574-582.

4. Yan, C., Yao, J., Li, R., Xu, Z., Huang, J. (2019). "Weakly Supervised Deep Learning for Thoracic Disease Classification and Localization on Chest X-rays." Proceedings of the ACM Conference on Health, Inference, and Learning, стр. 1-10.