

УДК 004.89

КОМБИНИРОВАННЫЙ ПОДХОД АВТОМАТИЧЕСКОЙ РАЗМЕТКИ
МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ

И. И. МИЩЕНКО

Научный руководитель А. Е. МИСНИК, канд. техн. наук
Белорусско-Российский университет
Могилев, Беларусь

Современные методы глубокого обучения демонстрируют впечатляющие результаты анализа медицинских изображений, однако их эффективность напрямую зависит от качества и объема обучающих данных. В области рентгенографии проблема анализа медицинских изображений осложняется необходимостью привлечения высококвалифицированных специалистов для разметки данных, что делает процесс создания датасетов крайне ресурсоемким. Особую сложность представляет диагностика патологий опорно-двигательного аппарата, где точность распознавания анатомических структур крайне важна для постановки диагноза.

Основной проблемой при создании датасетов является недостаток аннотированных изображений. Для её решения предлагается комбинированный подход, включающий:

1) предварительную слабую разметку с использованием сверточных нейронных сетей (CNN). Для начальной сегментации костных структур применяются предварительно обученные модели U-Net и Mask R-CNN, демонстрирующие высокую эффективность в задачах медицинской визуализации. Архитектура U-Net хорошо подходит для работы с ограниченным количеством данных, сохраняя при этом пространственную информацию. В свою очередь, Mask R-CNN, благодаря встроенному механизму генерации масок, используется для выделения сложных структур;

2) активное обучение (Active Learning). Следующим шагом подход реализует итеративный процесс, в котором начальная модель обучается на небольшом размеченном наборе, для каждого же неразмеченного изображения рассчитывается информативность (на основе uncertainty sampling). В свою очередь, для разметки эксперту предлагаются наиболее информативные образцы (10 %...15 % от общего объема), а затем модель переобучается с учетом новых данных. Так цикл повторяется до достижения заданной точности [1];

3) синтетическую аугментацию на основе генеративно-состязательных сетей (GAN). Для генерации реалистичных вариаций изображений используется модифицированная архитектура StyleGAN2-ADA, адаптированная под медицинские изображения.

Исследование проводилось на наборе из 1000 рентгеновских снимков позвоночника. Датасет включал несколько категорий патологий, среди которых остеопороз, компрессионные переломы и нормальные случаи.

Для оценки качества модели использовался F1-score – гармоническое среднее между точностью (precision) и полнотой (recall). Эта метрика особенно

важна в медицинской диагностике, т. к. она балансирует между ложными срабатываниями и пропущенными патологиями, устойчива к дисбалансу классов в данных, а также позволяет объективно сравнивать разные модели.

Результаты сравнивались с тремя базовыми методами, такими как полностью ручная разметка, автоматическая разметка без активного обучения и классические методы аугментации (поворот, масштабирование). В табл. 1 приведены результаты сравнительного анализа.

Табл. 1. Сравнительные характеристики методов

Метод	Время разметки	F1-score	Требуемые экспертные знания
Ручная разметка	100 %	0,95	Высокие
Автоматическая	30 %	0,81	Средние
Предложенный метод	60 %	0,94	Низкие

Из полученных результатов можно сделать выводы, что применение комбинированного подхода позволило сократить время разметки на 40 % по сравнению с полностью ручным методом, повысить точность сегментации на 13 % (F1-score) относительно базовой автоматической разметки, увеличить размер датасета в 3 раза за счет синтетических образцов, а также снизить требования к квалификации персонала.

Дальнейшими перспективными направлениями исследований являются развитие нейросетевых архитектур, оптимизация работы с данными и автоматизация контроля качества. Особое акцент необходимо уделить Vision Transformers, который, благодаря механизмам внимания, эффективно учитывает глобальный контекст, что повышает точность в задачах сегментации и генерации изображений.

Также перспективны облачные платформы для распределенной аннотации и интеллектуальные системы валидации разметки. Первые обеспечивают масштабирование, контроль качества и интеграцию с ML-инструментами, что значительно ускоряет подготовку данных. Вторые же используют активное обучение, слабый надзор и перенос знаний. Они выявляют ошибки, самообучаются и снижают необходимость ручной проверки, формируя основу нового поколения точных CV-систем.

Разработанный подход эффективно решает проблему недостатка размеченных медицинских данных, демонстрируя преимущества перед традиционными подходами. Дальнейшее развитие технологии открывает новые возможности для автоматизации медицинской диагностики.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. **Мищенко, И. И.** Применение технологий компьютерного зрения и предварительной обработки изображений в системах поддержки принятия решений / И. И. Мищенко, А. Е. Мисник, А. В. Александров // Вестник Самарского государственного технического университета. Серия: Технические науки. – 2024. – С. 6–26.