

УДК 004.8

ПРИМЕНЕНИЕ РАДИОМИЧЕСКИХ ПРИЗНАКОВ ДЛЯ КЛАССИФИКАЦИИ ПАТОЛОГИЙ ПЕЧЕНИ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

Ю.В. СТАРИЧКОВА, С.В. АНТОНЕНКО, Н.Ш. ГАЗАНОВА

РТУ МИРЭА, г. Москва, Россия

Аннотация. Данное исследование посвящено разработке и тестированию подходов к автоматизации диагностики патологий на основе радиомических признаков, извлечённых из медицинских изображений. С помощью библиотеки PyRadiomics были получены текстурные и структурные характеристики патологий печени, такие как гетерогенность и контрастность, которые позволяют более точно интерпретировать особенности снимков. В качестве классификаторов применялись алгоритмы CatBoost и LightGBM, зарекомендовавшие себя в анализе данных высокой размерности. Модели обучались и оценивались на основе метрик accuracy и F1-score для обеспечения высокой точности и надёжности классификации. В ходе экспериментов также исследовалось влияние увеличения объёма обучающей выборки за счёт добавления данных, полученных по результатам сегментации патологий с использованием библиотеки NNUnet. Результаты показали, что дополнение данных способствует улучшению ключевых метрик, что свидетельствует о потенциальной эффективности предложенного подхода для поддержки медицинской диагностики.

Ключевые слова: радиомические признаки, машинное обучение, медицинские изображения, диагностика патологий, CatBoost, LightGBM, PyRadiomics, классификация патологий, анализ изображений, расширение обучающей выборки.

THE USE OF RADIOMIC FEATURES FOR THE CLASSIFICATION OF LIVER PATHOLOGIES BY MACHINE LEARNING METHODS

YU.V. STARIKOVA, S.V. ANTONENKO, N.S. GAZANOVA

RTU MIREA Moscow, Russia

Abstract. This study aims to develop and test approaches to automate pathology diagnostics based on radiomic features extracted from medical images. Using the PyRadiomics library, textural and structural characteristics of liver pathologies, such as heterogeneity and contrast, were obtained, which allow for a more accurate interpretation of image features. CatBoost and LightGBM algorithms, which have proven themselves in high-dimensional data analysis, were used as classifiers. The models were trained and evaluated based on the accuracy and F1-score metrics to ensure high accuracy and reliability of classification. During the experiments, the effect of increasing the training sample size by adding data obtained as a result of pathology segmentation using the NNUnet library was also investigated. The results showed that data supplementation contributes to the improvement of key metrics, which indicates the potential effectiveness of the proposed approach for supporting medical diagnostics.

Keywords: radiomic features, machine learning, medical images, pathology diagnostics, CatBoost, LightGBM, PyRadiomics, pathology classification, image analysis, expansion of the training sample.

Введение

Автоматизация диагностики медицинских патологий с применением методов машинного обучения открывает новые возможности в области медицины, повышая точность и скорость анализа медицинских изображений. В последнее десятилетие сформировалось новое направление углубленного анализа цифровых изображений — радиомика, которая использует самые разнообразные математические методы обработки изображений, включая статистико-корреляционные и алгоритмы машинного обучения. Радиомика — это быстро развивающаяся область исследований, связанная с извлечением количественных показателей (текстурным анализом) областей интереса на медицинских изображениях.

В данное исследование были включены результаты КТ 620 пациентов, проходивших диагностику и лечение в 2022-2024 годах в медицинских учреждениях г. Москвы. У этих пациентов рентгенологически выявлены и гистологически подтверждены новообразования печени, относящиеся к четырём группам: простые кисты, гемангиомы, карцинома (HCR) и фокальная нодулярная гиперплазия (FNG). Деперсонифицированный набор данных для анализа был предоставлен Центром диагностики и телемедицины, г. Москва [1].

В данном исследовании радиомические признаки — метрики, отражающие текстурные и структурные характеристики изображения — стали основой для классификации различных типов патологий печени. Эти признаки были извлечены с использованием библиотеки PyRadiomics, которая позволяет количественно описывать особенности медицинских изображений.

В рамках предлагаемого подхода анализ радиомических признаков предполагается применять на завершающем этапе исследования, после получения результатов нейросетевой сегментации. Радиомика позволяет интегрировать знания специалистов с возможностями нейронных сетей, что повышает эффективность анализа. В перспективе, использование радиомических признаков может улучшить интерпретируемость нейросетевых моделей, позволяя врачам понимать, на основе каких характеристик принято решение.

Для классификации в предлагаемом исследовании применялись методы CatBoost и LightGBM, каждый из которых был настроен и проверен на предмет точности и полноты. Настоящее исследование направлено на оценку эффективности расширения обучающей выборки путем включения в нее радиомических признаков, извлеченных не только из результатов ручной разметки патологий, как рассмотрено в [1-3] но и из сегментаций, предсказанных моделью UNet.

Методика проведения эксперимента

Радиомические признаки представляют собой набор количественных показателей, которые можно извлечь из изображений для более глубокого анализа их текстуры, формы, интенсивности и других характеристик. Эти признаки находят широкое применение в задачах медицинской диагностики, так как позволяют выявить особенности патологий, недоступные при традиционном визуальном анализе. Основные категории радиомических признаков включают следующие группы[4].

1. Тектурные характеристики. К ним относятся гетерогенность и контрастность, которые описывают распределение яркостей и однородность области на изображении.

2. Формальные признаки. К ним относятся параметры, описывающие форму и структуру объектов, например, круглоту или вытянутость.

3. Гистограммные признаки. В этой группе находятся параметры распределения интенсивности яркости в изображении, позволяющие выявлять паттерны изменения плотности ткани.

Библиотека PyRadiomics предоставляет доступ к набору инструментов для автоматического извлечения таких признаков, упрощая процесс подготовки данных для машинного обучения.

Для задачи классификации использовались два наиболее популярных алгоритма градиентного бустинга: CatBoost и LightGBM. Эти методы широко применяются в задачах анализа данных высокой размерности и зарекомендовали себя как мощные инструменты для обработки сложных наборов признаков, таких как радиомические признаки, позволяя моделям эффективно извлекать значимую информацию для точной классификации патологий. Каждый из этих методов обладает уникальными особенностями, которые делают их особо ценными для анализа медицинских изображений.

– CatBoost — классификатор, адаптированный для работы с несбалансированными данными, что важно в условиях медицинской диагностики, где встречаются редкие патологии. CatBoost эффективно работает с категориальными признаками и позволяет получить хорошие результаты даже при ограниченном объеме обучающей выборки. Это делает его подходящим выбором для задач, требующих гибкости и надежности при анализе неравномерно представленных классов.

– LightGBM — алгоритм, который отличается высокой скоростью обучения без снижения точности. Этот метод оптимизирован для работы с большими объемами данных и

использует продвинутое техники для ускорения процесса вычислений. LightGBM обеспечивает быструю и эффективную обработку, что делает его особенно привлекательным при работе с радиомическими признаками в условиях ограниченных вычислительных ресурсов.

Результаты и их обсуждение

Основной целью эксперимента было исследование влияния увеличения обучающей выборки за счет прогнозов сети UNet на производительность моделей.

На первом этапе данные были разделены на тестовую и обучающую выборки, и модели обучались на основе радиомических признаков.

На втором этапе 40% данных, извлеченных из сегментаций, предсказанных моделью UNet на данных тестовой выборки, были добавлены в обучающую выборку, после чего модели были заново обучены и проверены на оставшейся части тестовой выборки. Сравнительные результаты метрик accuracy и F1-score между этапами показали, что добавление данных положительно сказалось на показателях точности классификации. Это указывает на то, что данные модели способны извлекать больше полезной информации при увеличении объема обучающих данных.

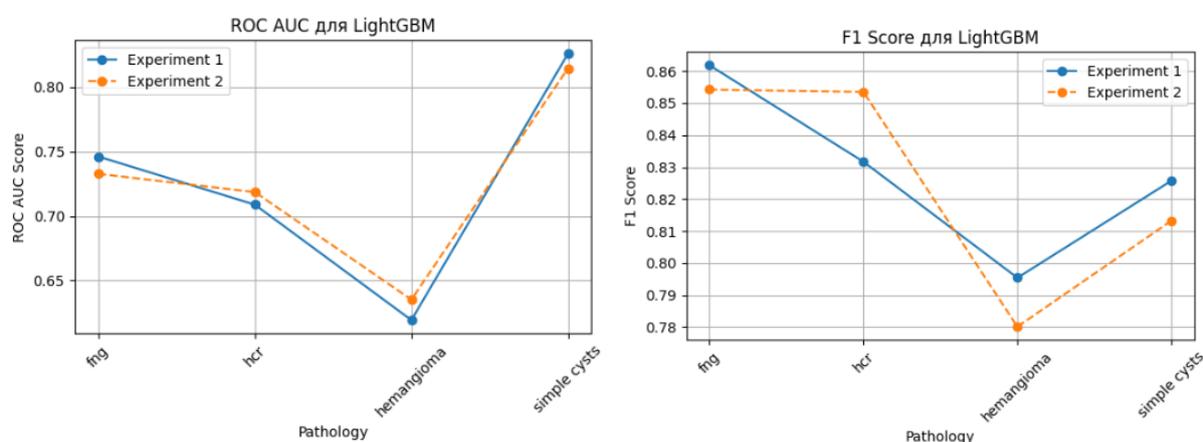


Рис. 1. Сравнение ROC AUC и F1_score у 1 и 2 эксперимента для LightGBM: a – ROC_AUC a; b – F1_score

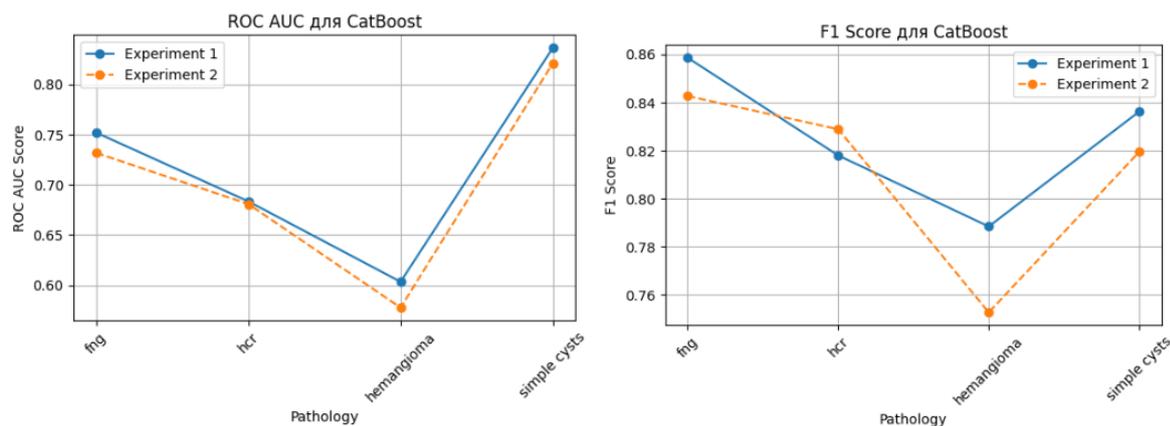


Рис. 2. Сравнение ROC AUC и F1_score у 1 и 2 эксперимента для CatBoost: a – ROC_AUC; b – F1_score

Проведенный эксперимент показал, что модели анализа радиомических признаков можно использовать для сегментаций, полученных сетью для повышения точности прогнозирования. В частности, точность прогнозирования ФНГ сетью UNet, реализованной в библиотеке NUNet без радиомических признаков составляла F1= 0.82, а с использованием радиомических признаков составила F1= 0.865.

Обе модели (LightGBM и CatBoost) продемонстрировали более высокие значения ROC AUC и F1 Score в первом эксперименте для гемангиом и ФНГ. Для карцином (наиболее опасной патологии) второй эксперимент показал более высокую точность. Патология *simple cysts* является единственной, где метрики остались на том же уровне или незначительно улучшились. Это может свидетельствовать о том, что добавление тестовых данных в обучающую выборку не всегда улучшает качество классификации и может даже привести к ухудшению результатов для некоторых классов патологий, вероятно, из-за изменения распределения данных или появления «шумовых» признаков.

Заключение

Проведённое исследование показало, что использование радиомических признаков в сочетании с методами машинного обучения эффективно для автоматизации классификации медицинских патологий. Добавление тестовых данных в обучающую выборку позволило улучшить метрики классификации по некоторым патологиям, что свидетельствует о перспективности такого подхода. Дальнейшие исследования могут быть направлены на оптимизацию моделей для более точного анализа медицинских изображений.

Список литературы

1. Использование радиомических признаков для классификации новообразований печени различной этиологии по данным компьютерной томографии / Ю. А. Васильев, Е. Ф. Савкина, А. А. Борисов [и др.] // Диагностическая и интервенционная радиология. 2024. Т. 18, № S2.1. С. 79-86.
2. Song J., Yin Y., Wang H., Chang Z., Liu Z., Cui L. A review of original articles published in the emerging field of radiomics //Eur J Radiol/ 2020. 127. P. 108991.
3. Kumar V., Gu Y. et al. Radiomics: the process and the challenges// Magn Reson Imaging, 2012. 30(9). P. 1234–1248,
4. Ramón Y Cajal S., Sesé M., Capdevila C. et al. Clinical implications of intratumor heterogeneity: challenges and opportunities.// J Mol Med (Berl). 2020. 98(2). P. 161–177.
5. Mirestean C.C., Pagute O., Buzea C. et al. Radiomic machine learning and texture analysis — new horizons for head and neck oncology// Maedica (Bucur). 2019 . 14(2). P. 126–130.
6. Lubner M.G., Smith A.D., Sandrasegaran K. et al. CT texture analysis: definitions, applications, biologic correlates, and challenges// Radiographics. 2017. 37(5). P.1483–1503.