

ISSN 1995-5464 (Print); ISSN 2408-9524 (Online)

<https://doi.org/10.16931/1995-5464.2025-4-44-51>

Оценка возможностей радиомики в определении степени дифференцировки гепатоцеллюлярного рака на КТ-изображениях

Санникова Л.А. *, Усталов А.А., Шмелева С.А., Шантаревич М.Ю., Кондратьев Е.В.

ФГБУ «Национальный медицинский исследовательский центр хирургии им. А.В. Вишневского» Минздрава России; 117997, Москва, ул. Большая Серпуховская, д. 27, Российская Федерация

Цель. Оценить эффективность и целесообразность применения методов машинного обучения в радиомике на примере компьютерных томограмм гепатоцеллюлярного рака.

Материал и методы. В исследование включили 42 пациента с патоморфологически подтвержденным гепатоцеллюлярным раком. Все пациенты прошли хирургическое лечение или получили консультации специалистов в период с января 2013 г. по декабрь 2022 г. Методом машинного обучения анализировали данные текстового анализа предоперационных компьютерных томограмм.

Результаты. При сравнении результатов модель AdaBoost продемонстрировала лучшие результаты в определении степени дифференцировки гепатоцеллюлярного рака Grade 3 по сравнению со стандартным статистическим анализом. Чувствительность была больше на 15,4%, специфичность — на 3,1%, диагностическая точность — на 15,31%.

Заключение. Применение машинного обучения в радиомике является многообещающим методом неинвазивной оценки степени гистологической дифференцировки гепатоцеллюлярного рака. Полученные данные могут быть использованы для решения ряда клинических и научных задач.

Ключевые слова: радиомика; гепатоцеллюлярный рак; машинное обучение; радиомические признаки; компьютерная томография

Ссылка для цитирования: Санникова Л.А., Усталов А.А., Шмелева С.А., Шантаревич М.Ю., Кондратьев Е.В. Оценка возможностей радиомики в определении степени дифференцировки гепатоцеллюлярного рака на КТ-изображениях. *Анналы хирургической гепатологии*. 2025; 30 (4): 44–51. <https://doi.org/10.16931/1995-5464.2025-4-44-51>

Авторы заявляют об отсутствии конфликта интересов.

Assessment of a CT-based radiomics model for predicting hepatocellular carcinoma grade

Sannikova L.A. *, Ustalov A.A., Shmeleva S.A., Shantarevich M.Yu., Kondratyev E.V.

A.V. Vishnevsky National Medical Research Center of Surgery of the Ministry of Healthcare of the Russian Federation; 27, Bol'shaya Serpukhovskaya str., Moscow, 117997, Russian Federation

Aim. To assess the effectiveness and feasibility of CT radiomics-based machine-learning models for hepatocellular carcinoma diagnosis.

Materials and Methods. The study included 42 patients with pathologically confirmed hepatocellular carcinoma. All patients underwent surgery or received medical advice between January 2013 and December 2022. Machine-learning algorithms were used to evaluate texture analysis data from preoperative CT scans.

Results. In comparative analysis, the AdaBoost model outperformed standard statistical methods in identifying Grade 3 hepatocellular carcinoma. Sensitivity was higher by 15.4%, specificity by 3.1%, and diagnostic accuracy by 15.31%.

Conclusion. The use of machine-learning based radiomics is a promising noninvasive method for evaluating the histological hepatocellular carcinoma grade. The obtained results may be applied in a variety of clinical and research contexts.

Keywords: radiomics; hepatocellular carcinoma; machine learning; radiomic features; computed tomography

For citation: Sannikova L.A., Ustalov A.A., Shmeleva S.A., Shantarevich M.Yu., Kondratyev E.V. Assessment of a CT-based radiomics model for predicting hepatocellular carcinoma grade. *Annaly khirurgicheskoy gepatologii = Annals of HPB surgery*. 2025; 30 (4): 44–51. <https://doi.org/10.16931/1995-5464.2025-4-44-51> (In Russian)

The authors declare no conflict of interest.

● Введение

Первичный рак печени является шестым по распространенности типом рака в мире, при этом гепатоцеллюлярный рак (ГЦР) составляет >80% всех впервые диагностированных наблюдений [1]. Цирроз печени любой этиологии является наиболее серьезным фактором риска, поскольку на его фоне развивается >90% наблюдений ГЦР. В Российской Федерации ГЦР занимает 13-е место среди заболеваний онкологического профиля и 11-е место среди всех причин смерти [2]. Лучевые методы исследования занимают центральное место в неинвазивной диагностике ГЦР. Рентгенологическая диагностика уникальна тем, что позволяет неинвазивным путем получать трехмерную информацию о заболевании, а также сравнивать исследования во времени. Также происходит постепенный переход к применению новых методик анализа диагностических изображений, полученных на основе изображений КТ, МРТ, УЗИ. Такие методы, как искусственный интеллект (ИИ) и радиомика, позволяют извлекать специфические признаки, которые содержат обширную информацию, недоступную для глаза человека. Алгоритмы машинного обучения (МО) продемонстрировали многообещающие результаты в различных областях медицины, в том числе в диагностике ГЦР [3–5].

ГЦР представляет собой агрессивную форму первичного рака, развивающуюся на фоне хронических заболеваний печени, наиболее часто ассоциированную с инфицированием вирусом гепатита В (HBV) или С (HCV), употреблением алкоголя или метаболическим синдромом. Также известно, что риск развития ГЦР значительно увеличивается с возрастом с наибольшей заболеваемостью к 70 годам [6]. Цирроз печени любой этиологии является наиболее важным и необратимым фактором риска ГЦР [7].

ГЦР диагностируют при помощи таких методов, как КТ, МРТ с гепатоспецифическим контрастным препаратом, чувствительность которых составляет 68–73,6 и 77,5%, специфичность — 93 и 94%, а пункционную биопсию выполняют все реже [8, 9]. Это связано, во-первых, с инвазивностью процедуры и возможным развитием осложнений — кровотечения и распространения опухоли вдоль пункционного канала. Во-вторых, неотъемлемым признаком злокачественного новообразования является внутриопухолевая гетерогенность, которая может меняться со временем и особенно в ответ на химиотерапевтическое лечение, поэтому биопсия одного анатомического участка опухоли может не отражать структуру всей опухоли. В-третьих, стоит отметить психологическое напряжение пациента во время выполнения инвазивных вмешательств. В связи с поздним появлением жалоб, недостаточностью

программ скрининга и, как следствие, несвоевременной и часто поздней постановкой диагноза ГЦР большинство пациентов не подвергаются радикальному лечению.

Наиболее важным аспектом в диагностике ГЦР является определение степени дифференцировки опухоли. Низкая ее степень ассоциируется с менее благоприятными клиническими исходами, такими как более короткая общая продолжительность жизни, повышенная частота рецидивов и повышенная агрессивность опухоли [10]. Наиболее распространенной считается гистологическая классификация Эдмондсона–Штайнера. Она позволяет классифицировать злокачественные новообразования печени на основе дифференцировки опухолевых клеток и ядерной атипии: I степень соответствует высокодифференцированным опухолям, а IV — низкодифференцированным [11]. Недостатком классификации является ее субъективность, поскольку результат во многом зависит от опыта и квалификации врача-патологоанатома. Применение возможностей текстурного анализа компьютерных изображений позволит с большей точностью определять степень дифференцировки опухоли и предоставляет важную прогностическую информацию, которая поможет клиницистам стратифицировать пациентов, планировать лечение и наблюдение.

Радиомика — это быстро развивающийся метод, который позволяет извлекать и анализировать количественные характеристики (радиомические признаки) из медицинских изображений, отражающих распределение значений пикселей или вокселей [12]. Однако интерпретация количественных данных человеком представляет собой сложную задачу; их извлечение возможно только с использованием компьютерных технологий и анализа при помощи сложных алгоритмов. Концепция радиомики, которая в значительной степени, но не исключительно, используется в онкологии, основывается на предположении, что биомедицинские изображения содержат информацию о процессах, специфичных для определенных заболеваний. Для анализа используют большой набор характеристик опухоли, включая текстуру, форму, интенсивность и пространственные отношения. Также эти параметры используют для отслеживания их изменений с течением времени, например, во время лечения или наблюдения. Эти изменения не могут быть оценены визуально, что требует поиска новых методов решения важных клинических задач, таких как радиомика. Для повышения точности текстурного анализа на текущем этапе развития лучевой диагностики активно внедряют методы ИИ. С помощью данных технологий можно увеличить воспроизводимость исследований, точность моделей.

Методика ИИ, наиболее часто применяемая для построения радиомических моделей, — МО, которое позволяет проанализировать множество признаков, выявить их связи между собой, включая нелинейные, что приводит к более высоким результатам. Значительную помощь в диагностике, предоперационном планировании лечения опухолей может оказать совместное применение МРТ и КТ с радиомикой. Также следует отметить, что радиомические признаки позволяют прогнозировать клинические исходы — выживаемость и реакцию на лечение. Если биопсия выявляет изменения только в небольшой части опухоли, при помощи радиомики возможно оценить всю опухоль, а также перитуморальную зону и нормальную паренхиму. Радиомика обеспечивает всестороннюю количественную оценку фенотипов опухоли путем извлечения и анализа большого числа радиомических признаков [13].

Радиомика включает несколько последовательных этапов [14–16]: получение изображений (КТ, МРТ, УЗИ, ПЭТ), предварительная обработка изображений, сегментация изображений, извлечение признаков для построения фенотипа изображения, разработка радиомической (диагностической или прогностической) модели.

С развитием технологий были разработаны новые методы ИИ, позволяющие решать более сложные задачи. МО и глубокое МО являются двумя важнейшими направлениями в этой сфере. МО предоставляет компьютерам возможность имитировать или воспроизводить человеческое поведение в процессе обучения, что способствует приобретению новых знаний и навыков, а также реорганизации уже имеющихся знаний для повышения собственной производительности.

В отличие от традиционного статистического анализа, включающего такие этапы, как сбор данных, их анализ, интерпретация результатов с последующим их представлением в виде отчетов, диаграмм и других способов отображения, которые помогают продемонстрировать результаты анализа, системы МО работают иначе. Им предоставляют данные, и они самостоятельно “разрабатывают” алгоритм для их обработки. Со временем точность этого алгоритма улучшается за счет “самообучения” системы на основе предыдущего опыта [17]. Таким образом, система совершает все меньше и меньше ошибок.

● Материал и методы

В исследование были включены 42 пациента (26 мужчин и 16 женщин) в возрасте 18–78 лет с патоморфологически подтвержденным ГЦР. Все пациенты прошли хирургическое лечение или получили консультации специалистов в период с января 2013 г. по декабрь 2022 г. Критериями

включения считали ГЦР любых размеров с последующей хирургической резекцией печени и с данными патоморфологического исследования, с указанием степени гистологической дифференцировки ГЦР согласно классификации ВОЗ. Включали предоперационные КТ органов брюшной полости с анализом нативной, артериальной, венозной и отсроченной фаз внутривенного контрастного усиления, выполненные в НМИЦ хирургии им. А.В. Вишневского или в других центрах по общепринятому протоколу. Все исследования были удовлетворительного качества и позволяли четко отобразить границы новообразования.

Критерии исключения: неудовлетворительное качество изображений и невозможность их оценки, наличие артефактов в зоне интереса; отсутствие одной из четырех фаз динамического контрастирования; отсутствие гистологического исследования; наличие в анамнезе предшествующего локорегионарного лечения до выполнения КТ.

КТ выполняли на томографе Philips Ingenuity 64 со следующими характеристиками: толщина среза 1,5 мм, напряжение на рентгеновской трубке 100 кВ, реконструкционный интервал 0,75 мм. Контрастный препарат с концентрацией йода 350–370 мг/мл вводили с помощью автоматического инжектора со скоростью 3,5–4 мл/с и сопровождали введением 25 мл физиологического раствора с той же скоростью. Для расчета необходимого объема контрастного препарата использовали формулу 1 мл/кг массы тела пациента, но не более 100 мл. Исследование с контрастированием выполняли методом “bolus tracking” с установкой трекера на уровне диафрагмы с порогом плотности 150 HU на нисходящей грудной аорте со стартом сканирования артериальной фазы на 10 с, венозной фазы на 38 с, отсроченной фазы исследования на 300 с.

Для построения радиомической модели анализа КТ пациентов с ГЦР были использованы методы МО, направленные на прогнозирование степени дифференцировки опухоли. Основная цель заключалась в определении предикторов низкодифференцированных опухолей (G3) по сравнению с высоко- и умеренно дифференцированными (G1, G2). Дифференцировка опухолей (G1–G3) была преобразована в бинарную задачу классификации: низкодифференцированные опухоли (G3) относились к классу 0, а высоко- и умеренно дифференцированные опухоли (G1 и G2) — к классу 1. Это преобразование облегчило интерпретацию результатов, поскольку наибольшее клиническое значение представляло выделение опухолей, которые имели худший прогноз. При обработке данных признаки с отсутствием вариативности удаляли. Такой подход обеспечил более высокое качество

входных данных, необходимых для построения устойчивой модели.

При отборе признаков для сокращения размерности данных и повышения точности моделей использовали метод SelectKBest на основе F-статистики ANOVA. После исключения нерелевантных характеристик, которые могут вносить “шум” и уменьшать эффективность обучения, было отобрано 25 наиболее значимых признаков. Они были стандартизированы для приведения их к единому масштабу. После отбора признаков данные были разделены на обучающую и тестовую выборки в соотношении 80:20 с сохранением пропорций классов (stratify).

На практике низкодифференцированные опухоли выявляют реже, чем высоко- и умеренно дифференцированные. Для устранения этого дисбаланса применяли метод SMOTE (Synthetic Minority Oversampling Technique), который искусственно увеличил число примеров миноритарного класса. Этот подход увеличил способность моделей корректно классифицировать редкие классы.

Оптимизацию гиперпараметров Random Forest выполняли с помощью сеточного поиска (GridSearchCV) по следующим критериям: количество деревьев, максимальная глубина деревьев, минимальное количество образцов для разбиения узла. Наилучшая конфигурация модели была определена на основе ROC AUC.

Далее создавали дополнительные “ансамблевые” модели, такие как Stacking Classifier (с использованием комбинации Random Forest, Gradient Boosting и XGBoost) и AdaBoost Classifier (с базовым классификатором Logistic Regression). Для обучения каждой модели использовали сбалансированную обучающую выборку. Для оценки моделей рассчитывали следующие метрики на тестовой выборке:

- **ROC AUC:** площадь под ROC-кривой;
- **PR AUC:** площадь под PR-кривой;
- **Accuracy:** точность;
- **Precision:** точность предсказания положительного класса;

- **Recall (Sensitivity):** чувствительность;
- **F1 Score:** гармоническое среднее точности и чувствительности;
- **Specificity:** специфичность.

После расчета строили матрицы ошибок для наглядной оценки результатов предсказания.

Для отображения результатов были построены ROC-кривые для всех моделей на тестовой выборке, а для анализа поведения моделей на разных объемах обучающей выборки и последующей оценки их обобщающей способности использовали кривые обучения.

При анализе результатов проводили сравнение всех моделей. Особое внимание было уделено модели с наивысшими метриками ROC AUC, PR AUC и F1 Score. Оценивали их применимость для диагностики степени дифференцировки ГЦР на основе данных КТ.

● Результаты

Модель, полученная ранее методом статистического анализа, характеризовалась следующими объяснительными (псевдо-R2 Нейглкёрка = 0,21) и дискриминативными (AUC = 0,78 [95% ДИ 0,63; 0,92]), скорректированный AUC = 0,71) характеристиками. Полученная диагностическая модель обладает чувствительностью 84,6%, специфичностью 71,9% и диагностической точностью 75,6% в определении степени дифференцировки ГЦР Grade 3 (табл. 1). На рис. 1 представлена диаграмма для оценки вероятности наличия низкой степени дифференцировки ГЦР (Grade 3) в зависимости от значения линейного предиктора. Результаты тестированных моделей показаны в табл. 2. На рис. 2 показана ROC-кривая моделей МО на тестовом наборе данных.

1. **Optimized Random Forest (ORF).** ROC AUC: 0,725; PR AUC: 0,832; Accuracy: 78,57%; Precision: 81,82%; Sensitivity: 90%; Specificity: 50%; F1 Score: 85,71%.

2. **Gradient Boosting.** ROC AUC: 0,675; PR AUC: 0,773; Accuracy: 71,43%; Precision: 80%; Sensitivity: 80%; Specificity: 50%; F1 Score: 80%.

Таблица 1. Диагностические характеристики пороговых значений предсказаний, полученных при использовании модели на основе текстурных признаков

Table 1. Diagnostic characteristics of threshold prediction values from the texture feature-based model

Характеристика	> 0,20	> 0,31*	> 0,40	> 0,50	> 0,60
Точность	57,8 [42,2; 72,3]	75,6 [60,5; 87,1]	71,1 [55,7; 83,6]	71,1 [55,7; 83,6]	73,3 [58,1; 85,4]
Чувствительность	84,6 [54,6; 98,1]	84,6 [54,6; 98,1]	38,5 [13,9; 68,4]	15,4 [1,9; 45,4]	15,4 [1,9; 45,4]
Специфичность	46,9 [29,1; 65,3]	71,9 [53,3; 86,3]	84,4 [67,2; 94,7]	93,8 [79,2; 99,2]	96,9 [83,8; 99,9]
NPV	88,2 [63,6; 98,5]	92,0 [74,0; 99,0]	77,1 [59,9; 89,6]	73,2 [57,1; 85,8]	73,8 [58,0; 86,1]
PPV	39,3 [21,5; 59,4]	55,0 [31,5; 76,9]	50,0 [18,7; 81,3]	50,0 [6,8; 93,2]	66,7 [9,4; 99,2]

Примечание: * — оценка Юдена, NPV — отрицательная прогностическая ценность, PPV — положительная прогностическая ценность.

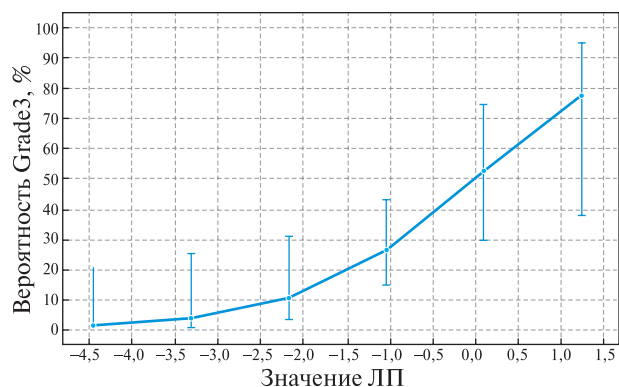


Рис. 1. Диаграмма. Оценка точности предсказаний, полученных в множественной логистической регрессионной модели. Точки соответствуют оценкам зависимости вероятности Grade 3 от значений линейного предиктора, вертикальные линии соответствуют стандартным ошибкам предсказаний.

Fig. 1. Prediction accuracy of the multiple logistic regression model. Points represent the probability of Grade 3 as a function of the linear predictor; vertical bars represent standard errors of prediction.

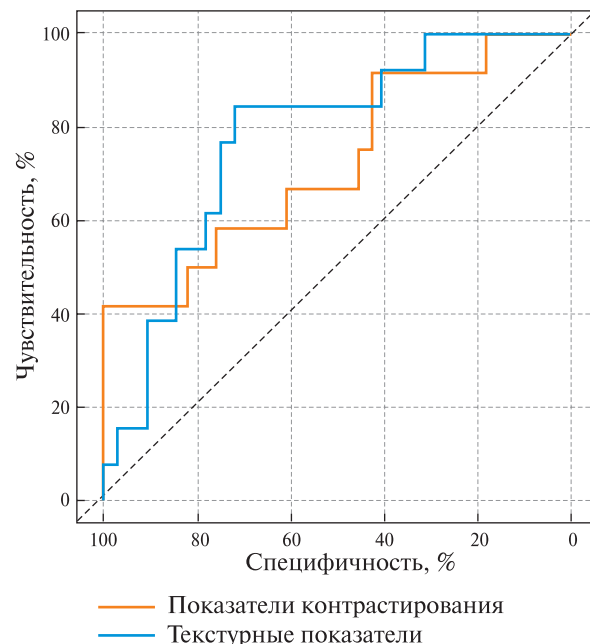


Рис. 2. Диаграмма. ROC-кривая моделей МО на тестовом наборе данных.

Fig. 2. ROC curves of machine learning models on the test dataset.

Таблица 2. Основные метрики моделей, используемых для классификации степени дифференцировки ГЦР

Table 2. Key metrics of models for differentiation of hepatocellular carcinoma grade

Модель	ROC AUC	PR AUC	Accuracy	Precision	F1 Score	Se	Sp
ORF	0,725	0,8322546897546897	0,7857142857142857	0,8181818181818182	0,8571428571428571	0,9	0,5
Gradient Boosting	0,675	0,7733658008658009	0,7142857142857143	0,8	0,8	0,8	0,5
XGBoost	0,55	0,7416008991008991	0,5714285714285714	0,7	0,7	0,7	0,5
LightGBM	0,6375	0,7716125541125541	0,6428571428571429	0,8571428571428571	0,7058823529411765	0,6	0,5
Stacking	0,7	0,8502888777888777	0,7857142857142857	0,8181818181818182	0,8571428571428571	0,9	0,5
AdaBoost	0,8	0,8813455988455987	0,9285714285714286	0,9090909090909091	0,9523809523809523	1,0	0,5

Примечание: Se – Sensitivity, Sp – Specificity.

3. **XGBoost.** ROC AUC: 0,55; PR AUC: 0,742; Accuracy: 57,14%; Precision: 70%; Sensitivity: 70%; Specificity: 25%; F1 Score: 70%.

4. **LightGBM.** ROC AUC: 0,637; PR AUC: 0,772; Accuracy: 64,29%; Precision: 85,71%; Sensitivity: 60%; Specificity: 75%; F1 Score: 70,59%.

5. **Stacking.** ROC AUC: 0,7; PR AUC: 0,850; Accuracy: 78,57%; Precision: 81,82%; Sensitivity: 90%; Specificity: 50%; F1 Score: 85,71%.

6. **AdaBoost.** ROC AUC: 0,8000; PR AUC: 0,8813; Accuracy: 92,86%; Precision: 90,91%; Sensitivity: 100%; Specificity: 75%; F1 Score: 95,24%.

Обсуждение

Рассмотрим основные метрики моделей, используемых для классификации степени дифференцировки ГЦР.

ORF продемонстрировала наилучший баланс между точностью, чувствительностью и F1-метрикой. Высокая чувствительность (90%) указывает на способность модели точно определять опухоли с низкой дифференцировкой (G3), что имеет клиническую значимость. Однако специфичность модели (50%) остается низкой, что свидетельствует о склонности модели к ложноположительным результатам.

Gradient Boosting показала несколько худшие результаты по сравнению с Random Forest. Хотя точность и чувствительность модели удовлетворительны, она менее эффективна в идентификации опухолей G3 (чувствительность 80%). Это может быть связано с меньшей способностью модели учитывать сложные зависимости между признаками.

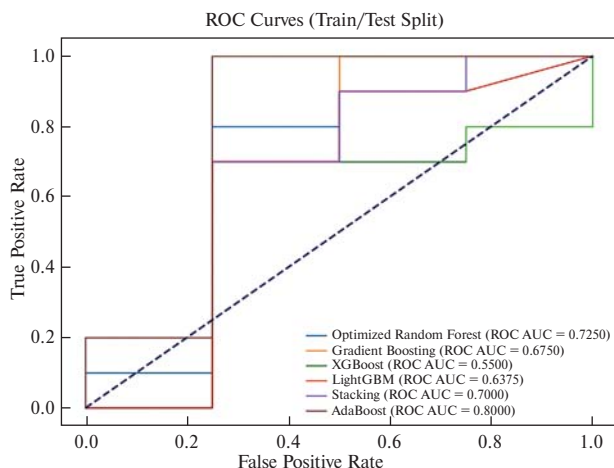


Рис. 3. Диаграмма. Матрица ошибок для модели AdaBoost.

Fig. 3. Confusion matrix for the AdaBoost model.

XGBoost оказалась наименее успешной среди всех моделей. Низкое значение ROC AUC (0,55) свидетельствует о слабой способности модели различать классы. Низкая специфичность (25%) также указывает на высокую склонность к ложноположительным предсказаниям. Это может быть связано с недостаточной настройкой гиперпараметров.

LightGBM продемонстрировала умеренные результаты. Высокая точность (85,71%) и специфичность (75%) свидетельствуют о способности модели правильно классифицировать G1/G2, однако низкая чувствительность (60%) указывает на недостаточную идентификацию G3. Это делает модель менее подходящей для задач, в которых важно минимизировать пропуск опухолей класса G3.

Stacking показала результаты, сравнимые с Random Forest. Высокие значения F1 (85,71%) и чувствительности (90%) делают эту модель одной из наиболее подходящих для решения задачи. Однако низкая специфичность (50%) указывает на риск ложных положительных классификаций.

Наилучшими моделями оказались ORF и Stacking, которые продемонстрировали высокие значения чувствительности (90%) и F1 (85,71%). Эти модели подходят для клинических задач, в которых важно минимизировать риск пропуска низкодифференцированных опухолей.

Модель XGBoost показала наименьшую эффективность, что может быть связано с недостаточной настройкой гиперпараметров. LightGBM лучше справляется с идентификацией классов G1/G2 (высокая точность и специфичность), однако недостаточно эффективна для классификации G3. Gradient Boosting продемонстрирова-

ла сбалансированные, но менее впечатляющие результаты по сравнению с Random Forest.

Выдающиеся результаты по сравнению с другими моделями продемонстрировала модель AdaBoost. Абсолютная чувствительность (100%) свидетельствует о том, что модель не пропустила ни одной опухоли с низкой дифференцировкой (G3). Высокая точность (90,91%) и F1 (95,24%) подтверждают отличное соотношение между истинно положительными и ложноположительными классификациями. Улучшенная специфичность (75%) в сравнении с другими моделями также свидетельствует об уменьшении числа ложноположительных результатов (рис. 3). Эти результаты делают AdaBoost особенно ценной для клинических задач, в которых пропуск G3 является критически недопустимым. Повышение специфичности также уменьшает риск ненужных дополнительных исследований для пациентов с G1/G2.

AdaBoost стала лидером среди всех протестированных моделей, обеспечив высокие результаты по всем метрикам. Однако стоит отметить, что исследование проводили на малой выборке, что предполагает необходимость дальнейшего изучения алгоритма для более полной и достоверной оценки результатов. Другие модели — ORF и Stacking — продемонстрировали хорошие результаты, но уступают AdaBoost по чувствительности, специфичности и F1. При сравнении с моделью, полученной методом статистического анализа, AdaBoost продемонстрировала лучшие результаты в выявлении степени дифференцировки ГЦР Grade 3: чувствительность была больше на 15,4%, специфичность — больше на 3,1%, диагностическая точность — больше на 15,31%.

Таким образом, применение технологий МО позволяет достигать более высоких показателей эффективности модели, чем классические статистические методы. Однако основным ограничением работы является небольшой размер выборки ($n = 42$). Исследование было сфокусировано на оценке классического (“handcrafted”) радиомического подхода, предполагающего явное извлечение признаков и их последующий анализ с помощью традиционных методов МО (в частности, таких моделей, как AdaBoost, Random Forest). Этот выбор был продиктован необходимостью изучить возможности улучшения именно этого широко используемого, воспроизводимого и интерпретируемого рабочего процесса (пайплайна), особенно в условиях ограниченных данных ($n = 42$), когда обучение глубоких нейронных сетей “с нуля” затруднительно, а transfer learning является отдельным направлением исследований. В рамках выбранного подхода были применены передовые ансамблевые методы МО. Для минимизации риска переобучения и оценки обобщающей способно-

сти моделей использовали независимую валидационную выборку, а для борьбы с дисбалансом классов — метод SMOTE. Следовательно, работа была посвящена сравнению и применению методов МО к табличным радиомическим данным, не затрагивая напрямую парадигму глубокого обучения.

● Заключение

Применение МО является многообещающим методом в диагностике онкологических заболеваний, в частности в неинвазивной оценке степени гистологической дифференцировки ГЦР. Алгоритмы МО предоставляют возможность более эффективно учитывать зависимости признаков, однако требуется больший набор данных для дальнейшего изучения этой проблемы.

Участие авторов

Санникова Л.А. — сбор и анализ данных, написание текста.

Усталов А.А. — сбор и анализ данных, научное редактирование.

Шмелева С.А. — научное редактирование.

Шантаревич М.Ю. — научное редактирование.

Кондратьев Е.В. — научное редактирование.

Все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией.

Authors contributions

Sannikova L.A. — data collection and analysis, writing text.

Ustalov A.A. — data collection and analysis, editing.

Shmeleva S.A. — editing.

Shantarevich M.Yu. — editing.

Kondratiev E.V. — editing.

All authors made substantial contributions to the study's conception, execution, and manuscript preparation, and they read and approved the final version prior to publication.

● Список литературы [References]

- Chao J., Zhao S., Sun H. Dedifferentiation of hepatocellular carcinoma: molecular mechanisms and therapeutic implications. *Am. J. Transl. Res.* 2020; 12 (5): 2099–2109.
- Бредер В.В., Косырев В.Ю., Кудашкин Н.Е., Лактионов К.К. Гепатоцеллюлярный рак в Российской Федерации как социальная и медицинская проблема. *Медицинский совет.* 2016; 10: 10–18. <https://doi.org/10.21518/2079-701X-2016-10-10-16>.
Breder V.V., Kosyrev V.Y., Kudashkin N.E., Laktionov K.K. Hepatocellular carcinoma as a social and medical problem in the Russian Federation. *Meditsinskiy sovet = Medical Council.* 2016; 10: 10–18. <https://doi.org/10.21518/2079-701X-2016-10-10-16> (In Russian)
- Ahn J.C., Qureshi T.A., Singal A.G., Li D., Yang J.-D. Deep learning in hepatocellular carcinoma: current status and future perspectives. *World J. Hepatol.* 2021; 13 (12): 2039–2051. <https://doi.org/10.4254/wjh.v13.i12.2039>
- Larrain C., Torres-Hernandez A., Larrain C. Artificial intelligence, machine learning, and deep learning in the diagnosis and management of hepatocellular carcinoma. *Livers.* 2024; 4 (1): 36–50. <https://doi.org/10.3390/livers4010004>
- Feng J., Wang L., Wang Q., Qiu D., Chen H., Su X., Li Y., Xiao Y., Lin C. Current status and analysis of machine learning in hepatocellular carcinoma. *J. Clin. Transl. Hepatol.* 2023; 11 (5): 1184–1191. <https://doi.org/10.14218/JCTH.2022.00077S>
- El-Serag H.B., Mason A.C. Rising incidence of hepatocellular carcinoma in the United States. *N. Engl. J. Med.* 1999; 340 (10): 745–750. <https://doi.org/10.1056/NEJM199903113401001>
- Zhang Z.-M., Huang Y., Liu G., Yu W., Xie Q., Chen Z., Huang G., Wei J., Zhang H., Chen D., Du H. Development of machine learning-based predictors for early diagnosis of hepatocellular carcinoma. *Sci. Rep.* 2024; 14 (1): 5274. <https://doi.org/10.1038/s41598-024-51265-7>
- Li J., Wang J., Lei L., Yuan G., He S. The diagnostic performance of gadoxetic acid disodium-enhanced magnetic resonance imaging and contrast-enhanced multi-detector computed tomography in detecting hepatocellular carcinoma: a meta-analysis of eight prospective studies. *Hepatobiliary-Pancreas.* 2019; 29 (12): 6519–6528. <https://doi.org/10.1007/s00330-019-06294-6>
- Hanna R.F., Miloshev V.Z., Tang A., Finklestone L.A., Brejt S.Z., Sandhu R.S., Santillan C.S., Wolfson T., Gamst A., Sirlin C.B. Comparative 13-year meta-analysis of the sensitivity and positive predictive value of ultrasound, CT, and MRI for detecting hepatocellular. *Abdominal Radiology.* 2016; 41 (1): 71–90. <https://doi.org/10.1007/s00261-015-0592-8>
- Qin X., Hu X., Xiao W., Zhu C., Ma Q., Zhang C. Preoperative evaluation of hepatocellular carcinoma differentiation using contrast-enhanced ultrasound-based deep-learning radiomics model. 2023. *J. Hepatocell. Carcinoma.* 2023; 10: 157–168. <https://doi.org/10.2147/JHC.S400166>
- Martins-Filho S.N., Paiva C., Azevedo R.S., Alves V.A.F. Histological grading of hepatocellular carcinoma — a systematic review of literature. *Front. Med.* 2017; 4: 193. <https://doi.org/10.3389/fmed.2017.00193>
- Кондратьев Е.В., Шмелева С.А., Усталов А.А., Гурина В.И., Кармазановский Г.Г. Теоретические основы текстурного анализа КТ-изображений образований органов брюшной полости: обзор. *Лучевая диагностика и терапия.* 2025; 16 (1): 33–46. <https://doi.org/10.22328/2079-5343-2025-16-1-33-46>
Kondratyev E.V., Shmeleva S.A., Ustalov A.A., Gurina V.I., Karmazanovsky G.G. Theoretical basics of abdominal CT radiomics: a review. *Diagnostic Radiology and Radiotherapy.* 2025; 16 (1): 33–46. <https://doi.org/10.22328/2079-5343-2025-16-1-33-46> (In Russian)
- Parmar C., Grossmann P., Bussink J., Lambin P., Aerts H.J.W.L. Machine learning methods for quantitative radiomic biomarkers. *Sci. Rep.* 2015; 5: 13087. <https://doi.org/10.1038/srep13087>
- McCague C., Ramlee S., Reinius M., Selby I., Hulse D., Piyatissa P., Bura V., Crispin-Ortuzar M., Sala E., Woitek R. Introduction to radiomics for a clinical audience. *Clin. Radiol.* 2023; 78 (2): 83–98. <https://doi.org/10.1016/j.crad.2022.08.149>
- Timmeren J.E., Cester D., Tanadini-Lang S., Alkadhi H., Baessler B. Radiomics in medical imaging — “how-to” guide and critical reflection. *Insights Imaging.* 2020; 11 (1): 91. <https://doi.org/10.1186/s13244-020-00887-2>
- Majumder S., Katz S., Kontos D., Roshkovan L. State of the art: radiomics and radiomics-related artificial intelligence on the

road to clinical translation. *BJR Open*. 2023; 6 (1): tzad004. <https://doi.org/10.1093/bjro/tzad004>

17. Кармазановский Г.Г., Кондратьев Е.В., Груздев И.С., Тихонова В.С., Шантаревич М.Ю., Замятина К.А., Сташків В.И., Ревішвили А.Ш. Современная лучевая диагностика и интеллектуальные персонализированные технологии в гепатопанкреатологии. Вестник РАМН.

2022; 77 (4): 245–253.

<https://doi.org/https://doi.org/10.15690/vramn2053>

Karmazanovsky G.G., Kondratyev E.V., Gruzdev I.S., Tikhonova V.S., Shantarevich M.Yu., Zamyatina K.A., Stashkiv V.I., Revishvili A.Sh. Modern radiation diagnostics and intelligent personalized technologies in hepatopancreatology. *Annals of the Russian Academy of Medical Sciences*. 2022; 77 (4): 245–253. <https://doi.org/10.15690/vramn2053>. (In Russian)

Сведения об авторах [Authors info]

Санникова Людмила Александровна — врач-ординатор отделения рентгенологии и магнитно-резонансных исследований ФГБУ “НМИЦ хирургии им. А.В. Вишневого” Минздрава России. <https://orcid.org/0009-0009-9802-3182>. E-mail: milasnkv@mail.ru

Усталов Андрей Александрович — младший научный сотрудник отделения рентгенологии и магнитно-резонансных исследований ФГБУ “НМИЦ хирургии им. А.В. Вишневого” Минздрава России. <http://orcid.org/0009-0005-9267-8584>. E-mail: andreiustalov@gmail.com

Шмелева София Антоновна — врач-ординатор отделения рентгенологии и магнитно-резонансных исследований ФГБУ “НМИЦ хирургии им. А.В. Вишневого” Минздрава России. <http://orcid.org/0009-0007-5724-2763>. E-mail: sofiaantonovna@gmail.com

Шантаревич Мария Юрьевна — канд. мед. наук, врач-рентгенолог отделения рентгенологии ФГБУ “НМИЦ хирургии им. А.В. Вишневого” Минздрава России. <http://orcid.org/0000-0002-4518-4451>. E-mail: shantarevichm@list.ru

Кондратьев Евгений Валерьевич — канд. мед. наук, заведующий отделением рентгенологии ФГБУ “НМИЦ хирургии им. А.В. Вишневого” Минздрава России. <http://orcid.org/0000-0001-7070-3391>. E-mail: evgenykondratiev@gmail.com

Для корреспонденции*: Санникова Людмила Александровна — e-mail: milasnkv@mail.ru

Lyudmila A. Sannikova — Resident Physician at the Department of Radiology and Magnetic Resonance Imaging, A.V. Vishnevsky National Medical Research Center of Surgery of the Ministry of Healthcare of the Russian Federation. <https://orcid.org/0009-0009-9802-3182>. E-mail: milasnkv@mail.ru

Andrey A. Ustalov — Junior Researcher at the Department of Radiology and Magnetic Resonance Imaging, A.V. Vishnevsky National Medical Research Center of Surgery of the Ministry of Healthcare of the Russian Federation. <http://orcid.org/0009-0005-9267-8584>. E-mail: andreiustalov@gmail.com

Sofia A. Shmeleva — Resident Physician at the Department of Radiology and Magnetic Resonance Imaging, A.V. Vishnevsky National Medical Research Center of Surgery of the Ministry of Healthcare of the Russian Federation. <http://orcid.org/0009-0007-5724-2763>. E-mail: sofiaantonovna@gmail.com

Mariia Yu. Shantarevich — Cand. of Sci. (Med.), Radiologist at the Department of Radiology, A.V. Vishnevsky National Medical Research Center of Surgery of the Ministry of Healthcare of the Russian Federation. <http://orcid.org/0000-0002-4518-4451>. E-mail: shantarevichm@list.ru

Evgeny V. Kondratyev — Cand. of Sci. (Med.), Head of the Radiology Department, A.V. Vishnevsky National Medical Research Center of Surgery of the Ministry of Healthcare of the Russian Federation. <https://orcid.org/0000-0001-7070-3391>. E-mail: evgenykondratiev@gmail.com

For correspondence*: Lyudmila A. Sannikova — e-mail: milasnkv@mail.ru

Статья поступила в редакцию журнала 31.03.2025.
Received 31 March 2025.

Принята к публикации 14.10.2025.
Accepted for publication 14 October 2025.