



Оригинальная статья

Разработка и внутренняя валидация предсказательной модели для прогнозирования класса очаговых образований печени при магнитно-резонансной томографии с помощью текстурного анализа (RadLiver)

Васильев Ю.А.¹ • Владимирский А.В.¹ • Голубев Ф.В.¹ • Омелянская О.В.¹ • Савин Н.А.¹ • Гордиенко Д.В.¹ • Блохин И.А.¹

Васильев Юрий Александрович –

д-р мед. наук, главный врач¹;
ORCID: <https://orcid.org/0000-0002-5283-5961>
✉ 127051, г. Москва, ул. Петровка, 24–1,
Российская Федерация.
E-mail: VasilevYA1@zdrav.mos.ru

Владимирский Антон Вячеславович –

д-р мед. наук, заместитель директора
по научной работе¹;
ORCID: <https://orcid.org/0000-0002-2990-7736>.
E-mail: VladimirskijAV@zdrav.mos.ru

Голубев Филипп Валентинович – врач-

рентгенолог отделения лучевой диагностики № 1¹;
ORCID: <https://orcid.org/0009-0003-7173-4888>.
E-mail: golubevfv@zdrav.mos.ru

Омелянская Ольга Васильевна – заместитель
директора по перспективному развитию, Дирекция
науки и Дирекция по перспективному развитию¹;
ORCID: <https://orcid.org/0000-0002-0245-4431>.
E-mail: OmelyanskayaOV@zdrav.mos.ru

Савин Никита Александрович –

канд. физ.-мат. наук, науч. сотр. отдела научных
медицинских исследований¹;
ORCID: <https://orcid.org/0000-0001-9199-7229>.
E-mail: savinna2@zdrav.mos.ru

Гордиенко Даниил Валерьевич –

инженер отдела инновационных технологий¹;
ORCID: <https://orcid.org/0009-0007-9813-3475>.
E-mail: gordienkovd2@zdrav.mos.ru

Блохин Иван Андреевич – канд. мед. наук,
зав. сектором исследований в лучевой диагностике¹;
ORCID: <https://orcid.org/0000-0002-2681-9378>.
E-mail: BlokhinIA@zdrav.mos.ru

Актуальность. Дифференциальная диагностика очаговых образований печени остается сложной задачей, особенно в ситуациях, когда применение контрастных препаратов при магнитно-резонансной томографии (МРТ) противопоказано (например, при почечной недостаточности или аллергии) или когда выявленные изменения на T2-взвешенных изображениях (T2-ВИ) не имеют патогномоничных признаков. В качестве дополнительного диагностического инструмента для поддержки принятия врачебных решений в таких клинических сценариях может выступать клинко-радиомическая модель, способная с высокой точностью классифицировать очаговые образования по данным нативных T2-ВИ.

Цель – разработка и внутренняя валидация клинко-радиомической модели для дифференциальной диагностики очаговых образований печени на основе T2-ВИ, полученных при МРТ.

Материал и методы. Проведено ретроспективное кросс-секционное одноцентровое исследование. Использован открытый анонимизированный набор данных WORC-Liver, содержащий T2-ВИ органов брюшной полости пациентов с очаговыми образованиями печени (данные собраны в Университете Эразма Роттердамского в 2002–2018 гг. на 1,5 T томографах Philips, Siemens, GE). Обработка изображений включала нормализацию (SimpleITK, Z-score) и интерполяцию до изотропного разрешения $1 \times 1 \times 1 \text{ мм}^3$. Радиомические признаки извлекались с использованием гистограмм и матриц серых тонов (PyRadiomics). Классификация выполнялась алгоритмом XGBoost с разделением выборки 80:20. **Результаты.** Из исходного набора данных в 186 случаев для анализа было отобрано 146 пациентов (72 со злокачественными и 74 с доброкачественными образованиями). На внутренней

валидационной выборке ($n = 30$) модель показала высокую диагностическую точность: AUC = 96% (95% доверительный интервал (ДИ) 0,89–1,00), чувствительность – 87% (95% ДИ 77–97), специфичность – 93% (95% ДИ 85–100). Анализ важности признаков выявил наибольший вклад следующих признаков: возраст пациента (SHAP +0,88), manufacturer: GE (SHAP +0,35), пол пациента (SHAP +0,29), original_gldm_DependenceNonUniformity (SHAP +0,17).

Заключение. Разработана высокоточная клинко-радиомическая модель для неинвазивной дифференциальной диагностики очаговых образований печени по нативным T2-ВИ, обладающая потенциалом для применения в клинической практике, особенно при противопоказаниях к контрастированию. Для внедрения необходимы дальнейшие исследования на более крупных и разнообразных наборах данных.

Ключевые слова: радиомика, текстурный анализ, машинное обучение, очаговые образования печени, магнитно-резонансная томография, T2-взвешенные изображения

Для цитирования: Васильев ЮА, Владимирский АВ, Голубев ФВ, Омелянская ОВ, Савин НА, Гордиенко ДВ, Блохин ИА. Разработка и внутренняя валидация предсказательной модели для прогнозирования класса очаговых образований печени при магнитно-резонансной томографии с помощью текстурного анализа (RadLiver). Альманах клинической медицины. 2025;53(5):260–267. doi: 10.18786/2072-0505-2025-53-024.

Поступила 21.08.2025; доработана 14.11.2025; принята к публикации 22.11.2025; опубликована онлайн 09.12.2025

¹ ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы»; 127051, г. Москва, ул. Петровка, 24–1, Российская Федерация



Диагностика очаговых образований печени (ООП) – одна из ключевых задач современной клинической практики. Масштабный ретроспективный анализ данных 45 319 пациентов, которым проводилось ультразвуковое исследование органов брюшной полости (как в рамках скрининга, так и по клиническим показаниям), показал, что у 15,1% от общего числа обследованных было идентифицировано как минимум одно ООП [1]. Для выявления гепатоцеллюлярного рака (ГЦР) рекомендуется многофазная компьютерная томография (КТ) и/или магнитно-резонансная томография (МРТ) печени и брюшной полости с контрастированием¹, при этом МРТ при сопоставимой с КТ специфичности характеризуется более высокой чувствительностью [2]. Вместе с тем существуют трудности дифференциальной диагностики злокачественных и доброкачественных ООП, обусловленные как объективным сходством изображений вследствие перекреста признаков, так и субъективными ошибками при их интерпретации [3–5].

Радиомика предлагает объективный подход к анализу изображений, извлекая из них сотни количественных признаков, неразличимых для человеческого глаза [6, 7]. В условиях вариативности протоколов МРТ при контрастном усилении Т2-взвешенные изображения (Т2-ВИ) представляют собой наиболее стандартизированный компонент исследования с высоким пространственным разрешением [8]. Это делает их прочной основой для построения воспроизводимых радиомических моделей, способных к обобщению данных из разных клиник.

Для оптимизации диагностики и персонализации лечебного процесса перспективным видится создание комбинированных моделей, которые наряду с радиомическими признаками Т2-ВИ учитывают и ключевые клинические данные. С помощью такого подхода можно получить надежный инструмент для поддержки принятия врачебных решений. В рамках настоящего исследования мы разработали алгоритм, основанный на комбинированном анализе радиомических признаков Т2-ВИ и клинических признаков, для дифференциальной диагностики ООП.

Цель – разработка и внутренняя валидация клинко-радиомической модели для дифференциальной диагностики ООП на основе Т2-ВИ, полученных при МРТ.

Материал и методы

В настоящем ретроспективном кросс-секционном исследовании объектом клинко-радиомического анализа были магнитно-резонансные (МР)

изображения органов брюшной полости (рис. 1), содержащие ООП, полученные из открытого набора данных WORC – WORC-Liver² [9]. Набор данных 186 пациентов содержит сведения о поле и возрасте пациентов, данные биопсии, а также Т2-ВИ, информацию о характеристиках МР-томографов, маски ООП. Для клинко-радиомического анализа было отобрано 146 случаев. Все изображения были получены в Университете Эразма Роттердамского (Роттердам, Нидерланды) с использованием томографов 1,5 Т производства Philips (Нидерланды), Siemens (Германия) и General Electric (США) (не менее 5 случаев на тип томографа) в период с 2002 по 2018 г.

Критериями включения в исследование были ГЦР, внутрипеченочная холангиокарцинома, гепатоцеллюлярная аденома или фокальная нодулярная гиперплазия; патологически подтвержденный фенотип; наличие Т2-ВИ МРТ. Критерии невключения: максимальный диаметр образования ≤ 3 см, фоновое заболевание печени, значительные артефакты при визуализации.

Исследование проводилось на базе ГБУЗ г. Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы» (ГБУЗ «НПКЦ ДиТ ДЗМ») в период с 4 ноября по 28 декабря 2024 г. Проведение ретроспективного исследования с вторичным использованием открытого набора данных одобрено независимым этическим комитетом Московского регионального отделения Российского общества рентгенологов и радиологов (протокол № 2/2025).

Сегментация изображений проводилась независимо двумя экспертами с опытом работы 21 год и 8 лет, которые не были осведомлены о характере изменений в печени.




Рис. 1. Пример МР-изображения из набора данных WORC – WORC Liver (источник: <https://xnat.health-ri.nl/data/projects/worc>)



Основной исход исследования: разработка клинко-радиомической модели и оценка показателей ее диагностической точности для дифференциации ООП по T2-ВИ. «Мягкая» конечная точка – прогноз бинарной классификации опухоли (доброкачественный или злокачественный тип образования).

Формирование репрезентативной выборки данных осуществляли согласно регламенту подготовки наборов данных ГБУЗ «НПКЦ ДиТ ДЗМ» [10]. Для разработки модели данные были разделены на обучающую (80%) и валидационную (20%) подгруппы с использованием стратифицированной выборки для сохранения баланса классов. Обучение алгоритма XGBoost проводили с применением 5-кратной кросс-валидации для минимизации переобучения и обеспечения обобщающей способности моделей [11]. Был также выполнен подбор оптимальных гиперпараметров алгоритма. Для оценки классификатора использовали значение площади под ROC-кривой (англ. area under the curve, AUC), полученное на валидационной выборке. Были рассчитаны показатели диагностической точности, включая чувствительность, специфичность, точность. Положительную и отрицательную прогностическую ценность не рассчитывали в связи с тем, что данные показатели при работе с WORC-Liver не отражают распространенность ООП в популяции (баланс классов 1:1).

Для обработки изображений применяли методы нормализации изображения, а также интерполяторы для преобразования вокселей и изображений масок в изометрические воксели размером $1 \times 1 \times 1 \text{ мм}^3$ [12]. Это обеспечивает однородность данных, поступающих с различных МР-томографов, что упрощает извлечение радиомических признаков и их анализ. Алгоритм нормализации изображения состоит из трансформации `sitk.Image` в трехмерный массив, применения метода нормализации `ZScoreNormalize` [13] и трансформации трехмерного массива в `sitk.Image` с сохранением информации об изображении.

Извлечение радиомических признаков производилось с использованием библиотеки `PyRadiomics` [14]. Были получены 11 текстурных признаков: `Original Firstorder Variance`; `Original GLCM Correlation`; `Original GLDM DependenceNonUniformity`; `Original GLDM GrayLevelNonUniformity`; `Original GLDM LargeDependenceLowGrayLevelEmphasis`; `Original GLRLM GrayLevelNonUniformity`; `Original GLRLM LongRunLowGrayLevelEmphasis`; `Original GLRLM RunLengthNonUniformity`; `Original GLSZM`

`LowGrayLevelZoneEmphasis`; `Original GLSZM ZoneEntropy`; `Original NGTDM Complexity`.

Для обеспечения сопоставимости и однородности признаков между различными МР-изображениями при извлечении текстурных признаков были выбраны следующие параметры: `binCount: 32`, `symmetricalGLCM: True`, `correctMask: True`.

Радиомические признаки объединяли с категориальными данными о наименовании производителя томографа (закодированными с использованием метода конвертации категориальных данных в бинарный формат `OneHotEncoding`) и демографическими данными пациентов (пол и возраст). На вход алгоритм классификации получал массив признаков и возвращал класс в виде значения 0 или 1, где 0 – доброкачественное образование, 1 – злокачественное.

Размер выборки для ретроспективной валидации бинарного теста был рассчитан с использованием методики, описанной в работе J.A. Hanley и B.J. McNeil [15]. Необходимый размер выборки составил $n = 130$ при вероятности совершения ошибок I и II типа, равной $\alpha = 0,05$ и $\beta = 0,2$ соответственно, ожидаемом значении $AUC = 0,9$, значении нулевой гипотезы $AUC = 0,8$, соотношении размеров выборок в отрицательных и положительных группах 1:1.

Для оценки эффективности разработанного алгоритма в различении ООП ($AUC > 80\%$) был рассчитан 95% доверительный интервал (ДИ). Статистически значимым результатом было превышение нижней границы 95% ДИ порогового значения, заданного как 80%. Вероятность равенства нижней границы 95% ДИ пороговому значению была оценена с помощью Z-теста, при условии нормальности распределения данных [16, 17]. В связи с малым размером внутренней валидационной выборки для оценки стабильности результатов была использована процедура бутстрэппинга с генерацией псевдовыборки до $n = 1000$. Уровень статистической значимости (p-value) принят равным 0,05. ROC-кривые были построены с использованием библиотек Python (`streamlit`, `SimpleITK`, `scipy`, `numpy`, `pandas`) и R-Studio версии не ниже 4.2.0 для анализа данных. Вклад показателей модели в прогноз был оценен с помощью библиотеки Python SHAP [18].

Результаты

Общее число случаев ООП, полученных из открытого набора данных WORC – WORC-Liver, составило 186 (134 женщины и 52 мужчины). Средний возраст женщин – 44,9 года (95% ДИ 42,4–47,4), мужчин – 58,5 года (95% ДИ 53,6–63,3).




Рис. 2. Блок-схема формирования выборки

Группу злокачественных новообразований составили 81 ГЦР и 13 внутриспеченочных холангиокарцином, доброкачественных – 48 гепатоцеллюлярных аденом и 44 фокальные нодулярные гиперплазии печени.

В исследование не было включено 40 случаев: с максимальным диаметром образования ≤ 3 см, фоновым заболеванием печени, значительными артефактами при визуализации. Из оставшихся 146 случаев 72 были злокачественными и 74 – доброкачественными очаговыми образованиями (рис. 2). Разделение выборки составляло 80:20 для обучающей и внутренней валидационной выборок соответственно.

После обучения клинко-радиомической модели при оценке на внутренней валидационной выборке из 30 пациентов были получены следующие показатели: чувствительность – 87% (95% ДИ 70–100), специфичность – 93% (95% ДИ 81–100), точность – 90% (95% ДИ 79–100), AUC = 0,9 (95% ДИ 0,89–1,00). Результаты представлены в матрице сопряженности (таблица). Алгоритм XGBoost показал высокую способность различать доброкачественные и злокачественные ООП. После бутстрэппинга 95% ДИ для AUC составил 0,89–1,00. При сравнении нижней границы ДИ с пороговым значением 0,8 Z-score составил 2,979 ($p = 0,001$).

При анализе вклада различных признаков в прогноз модели с использованием значений

SHAP (рис. 3 и 4) выявлено несколько ключевых закономерностей. Наиболее значимым признаком при прогнозировании злокачественного новообразования был возраст пациента (age). Получено значение SHAP +0,88, что указывает на большой положительный вклад признака «возраст пациента»: с увеличением возраста вероятность прогноза злокачественного новообразования возрастает.

Признак manufacturer: GE (МР-томограф производства General Electric, США) вносит отрицательный вклад в прогноз злокачественного новообразования, при этом вклад параметра в положительный прогноз мал.

Малый положительный вклад в прогноз модели вносят также параметры sex (пол) (значение SHAP +0,29) и sum of 12 other features (сумма 12 других клинко-радиомических признаков) (значение SHAP +0,25). Наибольший положительный вклад в прогноз модели из радиомических признаков вносит признак original_gldm_DependenceNonUniformity (неоднородность зависимости в изображении), его среднее значение SHAP составило +0,17.

Обсуждение

В последнее время все чаще появляются работы, в которых используются инструменты машинного обучения [19]. В частности, Ю.В. Молостова и соавт. предложили прогностические модели для дифференциации регенераторных и диспластических узлов, раннего ГЦР и узлов ГЦР с атипичным характером контрастирования. Ретроспективный анализ МР-изображений 72 пациентов с подозрением на опухолевое поражение печени на фоне цирроза с использованием текстурного анализа показал, что наиболее высокими дифференциальными возможностями обладала модель Random Forest при AUC = 0,91 [20].

Помимо внедрения стандартных моделей по типу Random Forest, проводится разработка автоматизированных систем, основанных на методах глубокого обучения, направленных на сегментацию и последующий анализ ООП [21]. Так, С.А. Hamm и соавт. [22] разработали систему глубокого обучения на основе сверточной нейронной

Матрица ошибок валидации классификатора очаговых образований печени

Референс-тест	Результаты работы обученного алгоритма	
	Отрицательный результат	Положительный результат
Отрицательный результат	14	1
Положительный результат	2	13




Рис. 3. SHAP-значения признаков комбинированной модели

сети, обученной на 43 400 примерах, созданных методами аугментации. Модель способна классифицировать распространенные ООП, визуализируемые при многофазной МРТ, с точностью до 92%. R. Nu и соавт. применили алгоритм генетического программирования для дифференциальной диагностики двух распространенных видов первичного рака печени по данным многофазной МРТ [23]. Ручная и автоматизированная сегментации были выполнены для выбора оптимальной модели машинного обучения, точность, чувствительность и специфичность которой составили 73% (95% ДИ 59–85), 70% (95% ДИ 48–89) и 71% (95% ДИ 52–90) соответственно. Разработанная R. Nu и соавт. модель классифицировала ГЦР и внутрипеченочную холангиокарциному с чувствительностью и специфичностью, сопоставимыми с показателями врачей-рентгенологов [23]. S. Lysdahlgaard в целях применения для задач классификации радиомических признаков, извлеченных из нормальной ткани или

опухоли печени, представил алгоритмы машинного обучения, включающие в себя оптимизацию гиперпараметров и 10-кратную кросс-валидацию [24]. Наивысшую производительность на тестовом наборе данных из 47 ООП показали Logistic regression, Random Forest и Support Vector Machine (100% чувствительность, специфичность и точность для каждой модели).

В настоящем исследовании разработана и валидирована комбинированная модель клиническо-радиомического анализа для дифференциальной диагностики ООП на основе Т2-ВИ. Показано, что радиомические признаки, извлеченные из МРТ, в комбинации с техническими характеристиками томографа, а также с такими характеристиками, как пол и возраст пациента, могут быть использованы для классификации ООП, что открывает перспективы для оптимизации диагностического процесса. Полученные результаты сопоставимы с показателями ведущих исследований в области радиомики печени и превосходят некоторые из них по точности диагностики.

Одно из ключевых преимуществ нашей модели заключается в возможности ее применения в ситуациях, когда использование контрастных препаратов при МРТ противопоказано или нежелательно, например, у больных с почечной недостаточностью или аллергией на контрастные вещества [25, 26]. В таких случаях анализ Т2-взвешенных МР-изображений с помощью предложенного алгоритма на основе радиомики может предоставить необходимую диагностическую информацию, повысив безопасность диагностического процесса. Разработанная модель может также служить инструментом «второго мнения», особенно в медицинском учреждении с небольшим штатом. В сложных случаях радиомический анализ может помочь врачу-рентгенологу принять более обоснованное решение, уменьшив вероятность ошибок и субъективных трактовок.

К ограничениям нашего исследования следует отнести небольшой объем выборки проанализированных случаев, что снижает обобщаемость модели и ее применимость в общей популяции. Ретроспективный и одноцентровый характер исследования также влияет на воспроизводимость полученных результатов в клинической практике. Поскольку в данной работе не проводилось прямого сравнения диагностической точности алгоритма и заключений врачей-рентгенологов, для однозначного вывода о клинической пользе алгоритма требуется проведение как минимум исследования в формате multireader-multicase. Планируется интерпретация исследований из набора данных в два




Рис. 4. Положительные средние SHAP-значения для комбинированной модели



этапа: без использования инструмента текстурного анализа и с ним; последующий расчет и сопоставление метрик точности позволят оценить влияние радиомического анализа на диагностическую эффективность врачей-рентгенологов. В нашем исследовании анализ методом SHAP выявил, что модель томографа имела высокую значимость для прогноза модели. Это может как отражать реальные различия в сигнале между аппаратами, так и указывать на наличие систематической ошибки. В частности, существует гипотетическая возможность, что врачи могли направлять пациентов с более сложными или подозрительными случаями на определенную модель томографа для получения изображений более высокого качества. Такая практика, если бы она имела место, могла бы искусственно завысить прогностическую важность этого признака в модели. Окончательное выяснение причин данной находки требует дальнейших исследований.

В будущем мы планируем провести внешнюю валидацию разработанной модели с использованием данных из Единого радиологического информационного сервиса (ЕРИС) Единой медицинской информационно-аналитической системы (ЕМИАС) г. Москвы. На этом этапе будет проверены обобщаемость и надежность модели на более широкой и разнообразной выборке, а также оценена ее способность работать с данными из различных медицинских учреждений и МР-томографов. Внешняя

валидация позволит не только более тщательно изучить применимость разработанных моделей, но и определить их потенциальное влияние на клиническую практику.

Заключение

В рамках определения возможностей клиничко-радиомического анализа нами была разработана и протестирована комбинированная модель для дифференциальной диагностики типа ООП по T2-взвешенным МР-изображениям. Полученные результаты демонстрируют перспективность предложенного подхода, который позволяет повысить объективность и точность диагностики за счет использования количественных признаков, извлеченных из изображений. Экспериментальное исследование показало, что алгоритм XGBoost обеспечивает высокие показатели точности классификации при использовании комбинации радиомических признаков, характеристик МР-томографа и демографических данных пациента, извлеченных из DICOM-тегов. Несмотря на некоторые ограничения, связанные с объемом выборки и ретроспективным характером исследования, разработанная система обладает потенциалом для применения в клинической практике. В дальнейшем целесообразно проведение внешней валидации системы на более крупных и разнообразных наборах данных. ©

¹ Пак печени (гепатоцеллюлярный). Клинические рекомендации Министерства здравоохранения Российской Федерации. Доступно по: https://cr.minzdrav.gov.ru/view-cr/1_3?ysclid=mihdz1u1f4511407720 (дата обращения 23.06.2025).

² Xnat.health-ri.nl [интернет]. XNAT. Health-RI. 2013–. Доступно по: <https://xnat.health-ri.nl/data/projects/worc> (дата обращения 23.06.2025).

Дополнительная информация

Финансирование

Данная статья подготовлена авторским коллективом в рамках НИР «Научное обоснование методов лучевой диагностики опухолевых заболеваний с использованием радиомического анализа» (№ ЕГИСУ 123031500005-2) в соответствии с приказом Департамента здравоохранения города Москвы от 17.12.2024 № 1184 «Об утверждении государственных заданий, финансовое обеспечение которых осуществляется за счет средств бюджета города Москвы, государственным бюджетным (автономным) учреждениям, подведомственным Департаменту

здравоохранения города Москвы, на 2025 год и плановый период 2026 и 2027 годов».

Конфликт интересов

Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Участие авторов

Ю.А. Васильев – концепция исследования, утверждение итогового варианта текста рукописи; Ф.В. Голубев – сбор и анализ литературных данных; И.А. Блохин – концепция

и дизайн исследования, редактирование текста рукописи, статистическая обработка; Н.А. Савин – написание и редактирование текста рукописи, сбор и анализ литературных источников; Д.В. Гордиенко – статистическая обработка; О.В. Омелянская, А.В. Владимирский – редактирование и утверждение текста рукописи. Все авторы прочли и одобрили финальную версию статьи перед публикацией, согласны нести ответственность за все аспекты работы и гарантируют, что ими надлежащим образом были рассмотрены и решены вопросы, связанные с точностью и добросовестностью всех частей работы.

Список литературы / References

- Kaltenbach TE, Engler P, Kratzer W, Oeztuerk S, Seufferlein T, Haenle MM, Graeter T. Prevalence of benign focal liver lesions: Ultrasound investigation of 45,319 hospital patients. *Abdom Radiol (NY)*. 2016;41(1):25–32. doi: 10.1007/s00261-015-0605-7.
- Roberts LR, Sirlin CB, Zaiem F, Almasri J, Prokop LJ, Heimbach JK, Murad MH, Mohammed K. Imaging for the diagnosis of hepatocellular carcinoma: A systematic review and meta-analysis. *Hepatology*. 2018;67(1):401–421. doi: 10.1002/hep.29487.
- Чжао АВ, Кармазановский ГГ, Бугаев СА, Чуринов АО. Трудности в диагностике и лечении очаговых заболеваний печени. *Альманах клинической медицины*. 2018;46(6):618–630. doi: 10.18786/2072-0505-2018-46-6-618-630. Zhao AV, Karmazanovsky GG, Bugaev SA, Churinov AO.



- gunov AO. [Diagnostic and treatment challenges in focal liver disease]. *Almanac of Clinical Medicine*. 2018;46(6):618–630. Russian. doi: 10.18786/2072-0505-2018-46-6-618-630.
4. Matos AP, Velloni F, Ramalho M, AlObaidy M, Rajapaksha A, Semelka RC. Focal liver lesions: Practical magnetic resonance imaging approach. *World J Hepatol*. 2015;7(16):1987–2008. doi: 10.4254/wjh.v7.i16.1987.
5. Li S, Zhou L, Chen R, Chen Y, Niu Z, Qian L, Fang Y, Xu L, Xu H, Zhang L. Diagnostic efficacy of contrast-enhanced ultrasound versus MRI Liver Imaging Reporting and Data System (LI-RADS) for categorising hepatic observations in patients at risk of hepatocellular carcinoma. *Clin Radiol*. 2021;76(2):161.e1–161.e10. doi: 10.1016/j.crad.2020.10.009.
6. Кармазановский ГГ, Кондратьев ЕВ, Груздев ИС, Тихонова ВС, Шантаревич МЮ, Замятина КА, Сташків ВИ, Ревішвили АШ. Современная лучевая диагностика и интеллектуальные персонализированные технологии в гепатопанкреатологии. *Вестник Российской академии медицинских наук*. 2022;77(4):245–253. doi: 10.15690/vramn2053. Karmazanovsky GG, Kondratyev EV, Gruzdev IS, Tikhonova VS, Shantarevich MY, Zamyatina KA, Stashkiv VI, Revishvili ASH. [Modern radiation diagnostics and intelligent personalized technologies in hepatopancreatology]. *Annals of the Russian Academy of Medical Sciences*. 2022;77(4):245–253. Russian. doi: 10.15690/vramn2053.
7. Замятина КА, Годзенко МВ, Кармазановский ГГ, Ревішвили АШ. Радиомика при заболеваниях печени и поджелудочной железы. Обзор литературы. *Анналы хирургической гепатологии*. 2022;27(1):40–47. doi: 10.16931/1995-5464.2022-1-40-47. Zamyatina KA, Godzenko MV, Karmazanovsky GG, Revishvili ASH. [Radiomics in liver and pancreatic disorders: A review]. *Annals of HPB Surgery*. 2022;27(1):40–47. Russian. doi: 10.16931/1995-5464.2022-1-40-47.
8. Кармазановский ГГ, Шантаревич МЮ, Сташків ВИ, Ревішвили АШ. Воспроизводимость текстурных показателей КТ- и МРТ-изображений гепатоцеллюлярного рака. Медицинская визуализация. 2023;27(3):84–93. doi: 10.24835/1607-0763-1372. Karmazanovsky GG, Shantarevich MY, Stashkiv VI, Revishvili ASH. [Reproducibility of CT and MRI texture features of hepatocellular carcinoma]. *Medical Visualization*. 2023;27(3):84–93. Russian. doi: 10.24835/1607-0763-1372.
9. Starmans M, Timbergen M, Vos M, Padmos G, Grunhagen D, Verhoef C, Sleijfer S, Leenders G, Buisman F, Willemsen F, Koerkamp B, Angus L, Veldt A, Rajicic A, Odink A, Renckens M, Doukas M, Man R, Ijzermans J, Klein S. (2021). The WORC database: MRI and CT scans, segmentations, and clinical labels for 930 patients from six radiomics studies. *medRxiv*. 2021:2021.08.19.21262238. doi: 10.1101/2021.08.19.21262238.
10. Морозов СП, Владзимирский АВ, Андрейченко АЕ, Ахмад ЕС, Блохин ИА, Гомболевский ВА, Зинченко ВВ, Кульберг НС, Новик ВП, Павлов НА. Регламент подготовки наборов данных с описанием подходов к формированию репрезентативной выборки данных. Часть 1: методические рекомендации. Серия «Лучшие практики лучевой и инструментальной диагностики». Выпуск 103. М.: ГБУЗ «НПКЦ ДиТ ДЗМ», 2022. 40 с. Morozov SP, Vladzimirsky AV, Andreychenko AE, Akhmad ES, Blokhin IA, Gombolevsky VA, Zinchenko VV, Kulberg NS, Novik VP, Pavlov NA. [Regulations on dataset preparation and approaches to representative data sampling. Part 1: Guidelines]. *Best Practices in Medical Imaging*. Issue 103. Moscow: Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Healthcare Department, 2022. 40 p. Russian.
11. Allen DM. The relationship between variable selection and data augmentation and a method for prediction. *Technometrics*. 1974;16(1):125–127. doi: 10.1080/00401706.1974.10489157.
12. Carré A, Klausner G, Edjlali M, Lerousseau M, Briend-Diop J, Sun R, Ammari S, Reuzé S, Alvarez Andres E, Estienne T, Niyoteka S, Battistella E, Vakalopoulou M, Dhermain F, Paragios N, Deutsch E, Oppenheim C, Pallud J, Robert C. Standardization of brain MR images across machines and protocols: Bridging the gap for MRI-based radiomics. *Sci Rep*. 2020;10(1):12340. doi: 10.1038/s41598-020-69298-z.
13. Reinhold JC, Dewey BE, Carass A, Prince JL. Evaluating the impact of intensity normalization on MR image synthesis. *Proc SPIE Int Soc Opt Eng*. 2019;10949:109493H. doi: 10.1117/12.2513089.
14. van Griethuysen JJM, Fedorov A, Parmar C, Hosny A, Aucoin N, Narayan V, Beets-Tan RGH, Fillion-Robin JC, Pieper S, Aerts HJWL. Computational radiomics system to decode the radiographic phenotype. *Cancer Res*. 2017;77(21):e104–e107. doi: 10.1158/0008-5472.CAN-17-0339.
15. Hanley JA, McNeil BJ. The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*. 1982;143(1):29–36. doi: 10.1148/radiology.143.1.7063747.
16. Eden T, Yates F. On the validity of Fisher's z test when applied to an actual example of non-normal data. *J Agric Sci*. 1933;23(1):6–17. doi: 10.1017/S0021859600052862.
17. Barri MA. A simulation showing the role of central limit theorem in handling non-normal distributions. *Am J Educ Res*. 2019;7(8):591–598. doi: 10.12691/education-7-8-8.
18. Lundberg S, Lee SI. A unified approach to interpreting model predictions. *arXiv*. 2017;arXiv:1705.07874. doi: 10.48550/arXiv.1705.07874.
19. Feng N, Wang K, Jiao Y. Integrating radiomics and machine learning for the diagnosis and prognosis of hepatocellular carcinoma. *World J Gastrointest Oncol*. 2025;17(7):106610. doi: 10.4251/wjgo.v17.i7.106610.
20. Молостова ЮВ, Медведева БМ, Кондратьев ЕВ, Усталов АА, Новрузбеков МС, Олисов ОД, Тарнопольский ВМ. Возможности текстурного анализа и машинного обучения в МРТ-диагностике раннего ГЦР. *Онкологический журнал: лучевая диагностика, лучевая терапия*. 2024;7(4):68–73. doi: 10.37174/2587-7593-2024-7-4-68-73. Molostova IV, Medvedeva BM, Kondratyev EV, Ustalov AA, Novruzbekov MS, Olisov OD, Tarnopolsky VM. [The capabilities of machine learning radiomics based models in the MRI diagnosis of early HCC]. *Journal of Oncology: Diagnostic Radiology and Radiotherapy*. 2024;7(4):68–73. Russian. doi: 10.37174/2587-7593-2024-7-4-68-73.
21. Gul S, Khan MS, Bibi A, Khandakar A, Ayari MA, Chowdhury MEH. Deep learning techniques for liver and liver tumor segmentation: A review. *Comput Biol Med*. 2022;147:105620. doi: 10.1016/j.combiomed.2022.105620.
22. Hamm CA, Wang CJ, Savic LJ, Ferrante M, Schobert I, Schlachter T, Lin M, Duncan JS, Weinreb JC, Chapiro J, Letzen B. Deep learning for liver tumor diagnosis part I: Development of a convolutional neural network classifier for multi-phasic MRI. *Eur Radiol*. 2019;29(7):3338–3347. doi: 10.1007/s00330-019-06205-9.
23. Hu R, Li H, Horng H, Thomasian NM, Jiao Z, Zhu C, Zou B, Bai HX. Automated machine learning for differentiation of hepatocellular carcinoma from intrahepatic cholangiocarcinoma on multiphasic MRI. *Sci Rep*. 2022;12(1):7924. doi: 10.1038/s41598-022-11997-w.
24. Lysdahlgaard S. Comparing radiomics features of tumour and healthy liver tissue in a limited CT dataset: A machine learning study. *Radiography (Lond)*. 2022;28(3):718–724. doi: 10.1016/j.radi.2022.03.015.
25. Davenport MS, Perazella MA, Yee J, Dillman JR, Fine D, McDonald RJ, Rodby RA, Wang CL, Weinreb JC. Use of intravenous iodinated contrast media in patients with kidney disease: Consensus statements from the American College of Radiology and the National Kidney Foundation. *Radiology*. 2020;294(3):660–668. doi: 10.1148/radiol.2019192094.
26. Ponrartana S, Moore MM, Chan SS, Victoria T, Dillman JR, Chavhan GB. Safety issues related to intravenous contrast agent use in magnetic resonance imaging. *Pediatr Radiol*. 2021;51(5):736–747. doi: 10.1007/s00247-020-04896-7.



Development and internal validation of a model to predict the class of focal liver lesions at magnetic resonance imaging by texture analysis

Yu.A. Vasilev¹ • A.V. Vladzimirskyy¹ • F.V. Golubev¹ •
O.V. Omelyanskaya¹ • N.A. Savin¹ • D.V. Gordienko¹ • I.A. Blokhin¹

Rationale: The differential diagnosis of focal liver lesions remains challenging, particularly in situations where the use of contrast agents in magnetic resonance imaging (MRI) is contraindicated (e.g., due to renal failure or allergy) or when the findings on T2-weighted images (T2WI) lack any pathognomonic signs. In these scenarios, an additional diagnostic tool is required to support decision-making, and a clinical-radiomic model capable of accurately classifying focal lesions based on T2WI data with accuracy and precision could be relevant.

Aim: To develop and perform internal validation of a clinical-radiomic model for the differential diagnosis of focal liver lesions based on T2WI.

Methods: This was a retrospective cross-sectional single-center study with an open anonymized WORC-Liver dataset, containing T2WI abdominal MRI images of patients with focal liver lesions (the original data collection performed at Erasmus Medical Center (Rotterdam, the Netherlands) between 2002 and 2018 using 1.5T Siemens, Philips, and General Electric scanners). Image processing included normalization (SimpleITK, Z-score) and interpolation to isotropic $1 \times 1 \times 1 \text{ mm}^3$ voxels. Radiomic feature extraction was performed using intensity histograms and gray-level matrices (PyRadiomics). The characteristics were classified using the XGBoost algorithm with an 80:20 train-validation split.

Results: From the initial dataset of 186 cases, 146 patients (72 with malignant and 74 with benign lesions) were selected for analysis. On the internal validation set ($n = 30$), the model showed high

diagnostic performance: ROC-AUC 96% (95% confidence interval [CI]: 0.89–1.00), sensitivity 87% (95% CI: 77–97), specificity 93% (95% CI: 85–100). The analysis of variable importance revealed the largest contributions from the following ones: patient age (SHAP +0.88), manufacturer: GE (SHAP +0.35), patient sex (SHAP +0.29), and original_gldm_DependenceNonUniformity (SHAP +0.17).

Conclusion: We were able to develop a high-accuracy clinical-radiomic model for the non-invasive differential diagnosis of focal liver lesions using native T2WI. The results demonstrate the model's potential for clinical application, particularly when the contrast administration is contraindicated. Its implementation would require further validation in larger and more diverse datasets.

Key words: radiomics, machine learning, texture analysis, liver, oncology, lesions, magnetic resonance imaging, T2-weighted MRI

For citation: Vasilev YuA, Vladzimirskyy AV, Golubev FV, Omelyanskaya OV, Savin NA, Gordienko DV, Blokhin IA. Development and internal validation of a model to predict the class of focal liver lesions at magnetic resonance imaging by texture analysis. Almanac of Clinical Medicine. 2025;53(5):260–267. doi: 10.18786/2072-0505-2025-53-024.

Received August 21, 2025; revised November 14, 2025; accepted for publication November 22, 2025; published online December 9, 2025

Funding

This paper was prepared by a team of authors as a part of the research project "Scientific substantiation of diagnostic radiology methods of tumors using radiomic analysis" (EGISU No. 123031500005-2) in accordance with the Order No. 1184 from December 17, 2024. "On approval of state assignments funded from the Moscow city budget to state budgetary (autonomous) institutions subordinated to the Moscow Healthcare Department for 2025 and the planning period of 2026 and 2027".

Conflict of interest

The authors declare no conflict of interests regarding the publication of this article.

Author's contribution

Yu.A. Vasilev, the study concept, approval of the final version of the manuscript; F.V. Golubev, literature collection and analysis; I.A. Blokhin, the study concept and design, text editing, statistical analysis; N.A. Savin, text writing and editing, literature search and analysis; D.V. Gordienko, statistical analysis; O.V. Omelyanskaya, A.V. Vladzimirskyy, text editing, approval of the final version of the manuscript. All the authors have read and approved the final version of the manuscript before submission, agreed to be accountable for all aspects of the work in ensuring that questions related to the accuracy or integrity of any part of the work are appropriately investigated and resolved.

Yuriy A. Vasilev – MD, PhD, Chief Physician¹;
ORCID: <https://orcid.org/0000-0002-5283-5961>
✉ Ul. Petrovka 24–1, Moscow, 127051, Russian Federation. E-mail: VasilevYA1@zdrav.mos.ru

Anton V. Vladzimirskyy – MD, PhD,
Deputy Director for Research¹;
ORCID: <https://orcid.org/0000-0002-2990-7736>.
E-mail: VladzimirskijAV@zdrav.mos.ru

Filipp V. Golubev – Radiologist,
Department of Diagnostic Radiology No. 1¹;
ORCID: <https://orcid.org/0009-0003-7173-4888>.
E-mail: golubevfv@zdrav.mos.ru

Oлга V. Omelyanskaya – Chief Innovation Officer
(CINO), R&D Directorate, Directorate of Innovation¹;
ORCID: <https://orcid.org/0000-0002-0245-4431>.
E-mail: OmelyanskayaOV@zdrav.mos.ru

Nikita A. Savin – PhD (in Phys.-Math.),
Research Fellow, Medical Research Department¹;
ORCID: <https://orcid.org/0000-0001-9199-7229>.
E-mail: savinna2@zdrav.mos.ru

Daniel V. Gordienko – Engineer,
Innovative Technologies Department¹;
ORCID: <https://orcid.org/0009-0007-9813-3475>.
E-mail: gordienkodv2@zdrav.mos.ru

Ivan A. Blokhin – MD, PhD,
Head of Sector for Radiology Research¹;
ORCID: <https://orcid.org/0000-0002-2681-9378>.
E-mail: BlokhinIA@zdrav.mos.ru

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department; ul. Petrovka 24–1, Moscow, 127051, Russian Federation