

ПОДБОР ОПТИМАЛЬНЫХ ИМПУЛЬСНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ И ФАЗ КОНТРАСТИРОВАНИЯ МРТ-ИССЛЕДОВАНИЯ ДЛЯ РАДИОМИЧЕСКОГО АНАЛИЗА В ДИАГНОСТИКЕ РАННЕГО ГЕПАТОЦЕЛЛЮЛЯРНОГО РАКА

Молостова Ю.В.¹✉, Медведева Б.М.¹, Геворкян Т.Г.¹, Кондратьев Е.В.², Усталов А.А.², Новрузбеков М.С.³, Олисов О.Д.³, Тарнопольский В.М.⁴

¹Национальный медицинский исследовательский центр онкологии им. Н.Н. Блохина Минздрава России; Россия, 115478, Москва, Каширское шоссе, 24

²Национальный медицинский исследовательский центр хирургии им. А.В. Вишневского Минздрава России; Россия, 115093, Москва, ул. Большая Серпуховская, 27

³Научно-исследовательский институт скорой помощи имени Н.В. Склифосовского Департамента здравоохранения города Москвы; Россия, 129090, Москва, Большая Сухаревская площадь, 3

⁴Филиал «Онкологический центр № 1 Городской клинической больницы имени С.С. Юдина Департамента здравоохранения города Москвы» Россия, 117152, Москва, Загородное шоссе, 18А, с. 7

✉ Молостова Юлия Викторовна, molostovajulia@yandex.ru, +7916091148

РЕФЕРАТ

Цель: Сравнение значимости различных последовательностей и фаз контрастирования МРТ-исследования для создания диагностической радиомической модели в МРТ-диагностике раннего гепатоцеллюлярного рака (ГЦР).

Материал и методы: Ретроспективно проанализированы данные 72 пациентов с 93 узловыми образованиями, прошедших МРТ-исследование с внутривенным контрастированием гепатоспецифическим МРКС «Примовист», проведена сравнительная оценка показателей четырех импульсных последовательностей и фаз контрастирования МРТ-исследования.

Результаты: В результате исследования были созданы радиомические модели различных импульсных последовательностей и фаз контрастирования МРТ-исследования с высокими дискриминативными возможностями, площадь под ROC-кривой (Area Under Curve, AUC) составила от 0,58 до 0,94 в различных моделях. Наилучшие показатели продемонстрировала модель Random Forest, построенная на основе данных МРТ-исследования в гепатоспецифическую фазу (ГСФ) — AUC 0,949684, при этом точность составила 0,825000. При сочетании различных импульсных последовательностей и 4 фаз контрастирования AUC составила 0,914342, точность повысилась до 0,846591.

Заключение: Наибольшие дискриминативные возможности для создания радиомических моделей диагностики ГЦР при МРТ имеют: самостоятельная гепатоспецифическая фаза внутривенного контрастирования, а также сочетание 4 МР-последовательностей и фаз внутривенного контрастирования.

Ключевые слова: гепатоцеллюлярный рак, МРТ, радиомика, текстурный анализ, гадокетовая кислота, фазы контрастирования

Для цитирования: Молостова Ю.В., Медведева Б.М., Геворкян Т.Г., Кондратьев Е.В., Усталов А.А., Новрузбеков М.С., Олисов О.Д., Тарнопольский В.М. Подбор оптимальных импульсных последовательностей и фаз контрастирования МРТ-исследования для радиомического анализа в диагностике раннего гепатоцеллюлярного рака. Онкологический журнал: лучевая диагностика, лучевая терапия. 2025;8(1):57-64.

<https://doi.org/10.37174/2587-7593-2025-8-1-57-64>

Journal of Oncology: Diagnostic Radiology and Radiotherapy

ISSN: 2587-7593 (Print) ISSN: 2713-167X (Online)

ЛУЧЕВАЯ ДИАГНОСТИКА | DIAGNOSTIC RADIOLOGY

<https://doi.org/10.37174/2587-7593-2025-8-1-57-64>

SELECTION OF OPTIMAL PULSE SEQUENCES AND ENHANCEMENT PHASES OF MRI STUDY FOR RADIOMICS ANALYSIS IN THE DIAGNOSIS OF EARLY HEPATOCELLULAR CARCINOMA

Iuliia V. Molostova¹✉, Bela M. Medvedeva¹, Tigran G. Gevorgyan¹, Evgeny V. Kondratyev², Andrey A. Ustalov², Murad S. Novruzbekov³, Oleg D. Olisov³, Vitaly M. Tarnoposky⁴

¹N.N. Blokhin National Medical Research Center of Oncology; 24 Kashirskoye Shosse, Moscow, Russia 115478

²A.V. Vishnevsky National Medical Research Center of Surgery; 27 Bolshaya Serpukhovskaya Moscow, Russia 115093

³The Scientific Department for Liver Transplantation, N.V. Sklifosovsky Research Institute for Emergency Medicine;

3 Bolshaya Suharevskaya ploshad, Moscow, Russia 129090

⁴S.S. Yudin State Clinical Hospital of the Department of Health Care of the Russian Federation;

18A building 7 Zagorodnoe shosse, Moscow, Russia 117152

✉ Iuliia V. Molostova, molostovajulia@yandex.ru, +7916091148

ABSTRACT

Purpose: To compare the importance of different MRI sequences and enhancement phases in creation of a diagnostic radiomics model in MRI diagnostics of early hepatocellular carcinoma (HCC).

Material and methods: Data from 72 patients with 93 masses who underwent Gadoteric acid-enhanced MRI scans was retrospectively analyzed, a comparative assessment of the indicators of four sequences and enhancement phases of MRI studies was performed.

Results: As a result of the study, machine-learning radiomics based models on various MRI sequences and enhancement phases with high discriminatory capabilities were created. The area under the ROC curve (Area Under Curve, AUC) ranged from 0.58 to 0.94 in various models; the best results were performed in Random Forest model based on MRI-hepatobiliary enhancement phase — AUC

0.949684, the combination of different enhancement sequences — AUC 0.914342.

Conclusion: The hepatobiliary phase of MRI study independently, as well as the combination of four enhancement phases and sequences of MRI study, have the greatest discriminatory capabilities for creating machine-learning radiomics based models on enhanced MR images in diagnostics of early HCC.

Key words: HCC, MRI, radiomics, gadoxetic acid, enhancement phases

For citation: Molostova I.V., Medvedeva B.M., Gevorkyan T.G., Kondratyev E.V., Ustalov A.A., Novruzbeikov M.S., Olisov O.D., Tarnoposky V.M. Selection of Optimal Pulse Sequences and Enhancement Phases of MRI Study for Radiomics Analysis in the Diagnosis of Early Hepatocellular Carcinoma. Journal of Oncology: Diagnostic Radiology and Radiotherapy. 2025;8(1):57-64. (In Russ.). <https://doi.org/10.37174/2587-7593-2025-8-1-57-64>

Введение

Распространенность злокачественных новообразований печени неуклонно увеличивается как в России, так и во всем мире, при этом гепатоцеллюлярный рак (ГЦР) является наиболее часто встречающимся видом злокачественных опухолей печени, занимая в России 13-е место в структуре онкологической заболеваемости и 11-е место среди всех причин смерти [1–4].

Первая система стандартизации критериев и стадирования ГЦР по критериям КТ и МРТ (LIRADS) была разработана в Американском колледже радиологии (ACR) и опубликована еще в 2011 г. К 2024 г. в системе появились обновления и дополнения, включающие УЗ-диагностику, алгоритмы скрининга и оценку эффективности лечения ГЦР. К настоящему времени LIRADS позволяет поставить диагноз ГЦР без морфологической верификации у пациентов с циррозом печени на основе данных МРТ, КТ и в ряде случаев УЗ-исследований с контрастным усилением [5–8].

Однако, несмотря на эффективность методов диагностики и стандартизованные семиотические признаки, дифференциальная диагностика ГЦР все еще вызывает большие трудности [7].

Для улучшения качества диагностики внедряются современные технологии, лежащие на стыке различных наук, позволяющие извлекать, использовать и анализировать большой массив данных, полученных из медицинских изображений, например, радиомика [9].

В процессе обработки МРТ-изображения происходит высокопроизводительное извлечение, анализ и интерпретация количественных признаков из томограмм. Текстуриный анализ изображений является частью радиомики и обеспечивает объективную количественную оценку неоднородности опухоли путем распределения и взаимосвязи уровней серого в пикселях или вокселях изображений [10–12].

Методы искусственного интеллекта (ИИ) позволяют создавать алгоритмы и модели, способные автоматически извлекать признаки из данных, решать задачи или предсказывать результаты на их основе.

Главной целью радиомики в сочетании с методами машинного обучения является возможность

построения стандартизированных прогностических моделей, основанных на специфических признаках изображения, выявленных при компьютерном анализе, которые позволят дифференцировать доброкачественные и злокачественные образования [13].

На сегодняшний день существует ряд ограничивающих факторов применения методов ИИ и текстурного анализа в клинической практике. Одним из лимитирующих факторов является отсутствие стандартизованных алгоритмов подбора фаз и импульсных последовательностей (ИП) исследования для включения в датасеты и последующей обработки, что обуславливает низкую воспроизводимость полученных результатов и, соответственно, низкие дискриминативные способности моделей [14].

Одним из актуальных вопросов для стандартизации и важным критерием для разработки диагностической радиомической модели является выбор необходимых фаз и ИП при использовании МР-томограмм. Основываясь на своем личном опыте, исследователи часто используют те фазы исследования, которые обладают наиболее яркими скialogическими чертами при визуальном анализе томограмм [15].

Однако, учитывая возможность текстурного анализа находить неочевидные закономерности в распределении интенсивности на медицинских изображениях, невидимые человеческому глазу, оптимальным подходом является использование наибольшего количества фаз, по крайней мере, на первичном этапе предварительного анализа данных. При этом использование нескольких фаз исследования значительно затрудняет процесс разметки, требуя больших временных и экономических затрат. Для изучения важности оценки нескольких фаз и ИП МР-исследования был проведен анализ текстурных показателей, а также проведено несколько экспериментов машинного обучения.

Материал и методы

В ретроспективное исследование было включено 72 пациента с подозрением на опухолевое поражение печени на фоне цирроза, проходивших обследование и лечение в Национальном медицинском исследовательском центре онкологии им. Н.Н. Блохина Минздрава России в

2019–2023 гг. Всем пациентам были выполнены МРТ-исследования на магнитно-резонансном томографе MAGNETOM Aera 1,5T (Siemens, Германия) с использованием стандартных протоколов исследования печени [12]. После установки локализатора в трех проекциях (T_2), в аксиальных проекциях выполнялись исследования в режимах T_1 vibe dixon, T_1 vibe dixon in phase и T_1 vibe dixon out-of-phase, далее внутривенно от руки вводился контрастный препарат, содержащий 10 мл гадооксеновой кислоты (в виде динариевого соли), из расчета 0,1 мл/кг, и в режиме T_1 vibe dixon начиналось сканирование в артериальную фазу. На 60-й секунде сканирования выполнялась портоvenозная фаза, на 180-й — переходная. Далее в 3 проекциях выполнялись T_2 haste протоколы, ДВИ при b-факторе 400 и 800 с/мм².

Для достижения гепатоспецифической фазы (ГСФ) исследования выполнялись спустя 10 мин после введения контрастного препарата в T_1 vibe dixon в аксиальной и корональной проекциях и спустя 20 мин в аксиальной проекции.

После тщательного анализа у 72 пациентов было выявлено 93 узловых образования, из них у 21 пациента было отобрано 32 верифицированных узла ГЦР, у 10 пациентов — 10 верифицированных узлов ГЦР с атипичным характером контрастирования, у 12 пациентов — 20 регенераторных узлов, у 29 пациентов — 39 диспластических узлов, 8 из которых были морфологически верифицированы. С помощью текстурного анализа были проанализированы нативная T_1 -ВИ, T_2 -ВИ, T_1 -ГСФ_{20мин}, ДВИ последовательности, в общей сложности 372 последовательности.

Для проведения текстурного анализа был использован модуль Radiomics в ПО 3D Slicer [16].

Работа данного модуля реализуется на основе открытого кода Pyradiomics [17].

Для изучения важности оценки нескольких фаз и ИП МРТ-исследования был проведен анализ текстурных показателей, а также проведено несколько экспериментов машинного обучения.

Результаты

На первом этапе для оценки вклада различных МРТ-последовательностей в многоклассовую классификацию была использована модель Random Forest в качестве средства отбора показателей. Путем сравнения метрик моделей машинного обучения было определено оптимальное количество показателей — 25 (рис. 1).

На втором этапе было произведено распределение признаков по группам, в зависимости от ИП и фаз контрастирования МРТ-исследования:

DWI (b-value 600) — (группа ДВИ) — 9 признаков

T_1 -ВИ НФ (группа T_1) — 5 признаков

T_2 -ВИ (группа T_2) — 5 признаков

T_1 -ГСФ_{20 мин} (группа ПОСТ) — 6 признаков

Далее была произведена оценка средней точности их предикции (рис. 2).

Группа ДВИ: Средняя точность: 0,6300

Группа T_2 : Средняя точность: 0,4600

Группа T_1 : Средняя точность: 0,5800

Группа ПОСТ: Средняя точность: 0,5800

При сравнении значимости признаков при ANOVA тесте различия оказались незначимые ($p > 0,2$):

Группа ДВИ: 0,031211

Группа T_2 : 0,018221

Группа T_1 : 0,018697

Группа ПОСТ: 0,020737




Рис. 1. График 25 наиболее важных радиомических признаков в многоклассовой модели машинного обучения
Fig. 1. Graph of 25 the most important radiomic features in the multiclass classifying machine learning model




Рис. 2. График распределения средней точности для каждой группы радиомических признаков

Fig. 2. Graph of the distribution of the average accuracy for each group of radiomic features

При аналогичном подходе отбора показателей внутри одной лишь группы (ИП) распределение средней значимости топ-20 признаков отличалось от средней точности мультипараметрической модели:

Группа ДВИ: 0,03333333333333333

Группа T₂: 0,06666666666666668

Группа T₁: 0,03125

Группа ПОСТ: 0,043478260869565216

Во втором эксперименте на первом этапе каждой ИП или фазе контрастирования МР-исследования присваивался свой класс (scenario — сценарий):

1 — ДВИ

2 — T₁-ВИ НФ

3 — T₂-ВИ

4 — T₁-ГСФ_{20мин} (ПОСТ)

Далее отобранные ранее текстурные показатели были проанализированы 6 методами машинного обучения.

Нами были использованы 6 наиболее часто применяемых в мировой литературе алгоритмов машинного обучения, демонстрирующих наиболее высокие результаты:

Random Forest Classifier, Decision Tree Classifier, Logistic Regression, Gradient Boosting Classifier, Support Vector Machine, K Neighbors Classifier [15-20]. Полученные данные приведены в сводной табл. 1, дискриминативные способности отражены в графике (рис. 3):

Далее в эксперименте в одной модели мы сочетали различные фазы контрастирования и МР-

Таблица 1. Сводная таблица результатов моделей машинного обучения по отдельным импульсным последовательностям и фазам контрастирования МРТ-исследования

Table 1. Summary table of results of machine learning models by individual MRI-sequences and enhancement phases

№	model	precision	recall	f1	accuracy	roc_auc
0	Random Forest	0.791667	0.750000	0.743137	0.70	0.886161
1	Decision Tree	0.708333	0.708333	0.651471	0.65	0.792535
2	Logistic Regression	0.450000	0.552083	0.475830	0.45	0.695685
3	Gradient Boosting	0.763393	0.718750	0.709280	0.65	0.822173
4	Support Vector Machine	0.171875	0.260417	0.195833	0.40	0.738095
5	K-Nearest Neighbors	0.581250	0.468750	0.503472	0.50	0.772135
6	Random Forest	0.825000	0.781250	0.777778	0.75	0.949684
7	Decision Tree	0.625000	0.708333	0.636111	0.60	0.781002
8	Logistic Regression	0.523810	0.593750	0.516484	0.50	0.814174
9	Gradient Boosting	0.379167	0.416667	0.388095	0.45	0.795573
10	Support Vector Machine	0.250000	0.333333	0.266667	0.50	0.686198
11	K-Nearest Neighbors	0.550000	0.447917	0.476068	0.45	0.718285
12	Random Forest	0.737500	0.625000	0.650000	0.65	0.887742
13	Decision Tree	0.343750	0.375000	0.357143	0.45	0.585565
14	Logistic Regression	0.416667	0.375000	0.392857	0.45	0.589410
15	Gradient Boosting	0.666667	0.583333	0.593137	0.60	0.810888
16	Support Vector Machine	0.216667	0.302083	0.243083	0.45	0.713108
17	K-Nearest Neighbors	0.337302	0.354167	0.338095	0.45	0.722377
18	Random Forest	0.825000	0.781250	0.777778	0.75	0.949684
19	Decision Tree	0.625000	0.708333	0.636111	0.60	0.781002
20	Logistic Regression	0.523810	0.593750	0.516484	0.50	0.814174
21	Gradient Boosting	0.379167	0.416667	0.388095	0.45	0.795573
22	Support Vector Machine	0.250000	0.333333	0.266667	0.50	0.686198
23	K-Nearest Neighbors	0.550000	0.447917	0.476068	0.45	0.718285




Рис. 3. Графики ROC-кривых в оценке метрик сценариев по отдельным ИП и фазам контрастирования МРТ-исследования при сравнении 6 моделей машинного обучения

Fig. 3. ROC curve plots in the estimation of scenario metrics by individual MRI-sequences and enhancement phases in comparison of six machine learning models

последовательности. Для данного эксперимента было разработано 4 сценария запуска машинного обучения.

К первому сценарию (scenario 1) была отнесена уже оцененная ранее модель, основанная на текстурных показателях гепатоспецифической фазы МРТ-исследования, так как она показала лучшие метрики ROC AUC на модели Random Forest — 0,949684.

Вторым сценарием (scenario 2) стало добавление к этой модели данных, использованных при обучении модели T₁-ВИ.

Третьим сценарием (scenario 3) стало добавление к сценарию 2 показателей ИП ДВИ.

Четвертым сценарием (scenario 4) стало использование всех серий, отобранных в исследование.

Распределение сценариев происходило в порядке уменьшения важности групп признаков на основании метрик точности модели обучения Random Forest.

Сравнение сценариев происходило последовательно с предыдущим (табл. 2, рис. 4).

Как видно из таблиц и графиков, площадь под ROC-кривой (Area Under Curve, AUC) составила от 0,58 до 0,94 в различных моделях, при этом наилучшие показатели продемонстрировала модель Random Forest, построенная на основе данных МРТ — исследования в ГСФ — AUC 0,949684, при этом точность составила 0,825000. При сочетании различных последовательностей и 4 фаз контрастирования AUC составила 0,914342, точность повысилась до 0,846591.

Обсуждение

Целью нашей работы являлось изучение различных ИП и фаз контрастирования МРТ-исследования для выявления наиболее важных из них или их комбинаций при создании радиомических моделей для диагностики ГЦР. В мировой практике группы исследователей используют различные ИП и фазы контрастирования МР-исследований, опираясь на наиболее репрезентативные лучевые признаки.

Так, Zhen et al [21] при создании радиомической модели для дифференциальной диагностики ГЦР и других объемных образований в печени в своих датасетах использовали данные 3 последовательностей: T₁-ВИ без контрастного усиления, T₂-ВИ и ДВИ или 6: T₁-ВИ без контрастного усиления, T₂-ВИ и ДВИ, T₁ позднюю артериальную, T₁ порталную и T₁ выделительную фазы. Результаты созданных моделей сравнивали с заключениями трех радиологов — экспертов по дифференциальной диагностике объемных образований печени и распределению их на 7 категорий. Так, модель, основанная на 3 нативных ИП, имела показатели AUC 0,946, при добавлении клинических данных ее показатели увеличились до AUC 0,985 в дифференциальной диагностике ГЦР, когда согласованность между врачами — экспертами составила 91,9%.

В исследовании Mao et al [22] оценивали возможности моделей искусственного интеллекта в выявлении и дифференциальной диагностике ГЦР и ФНГ.

Таблица 2. Сводная таблица результатов моделей машинного обучения по 4 сценариям сочетания последовательностей и фаз контрастирования МРТ-исследования

Table 2. Summary table of results of the machine learning models based on 4 scenarios of combining MRI-sequences and enhancement phases

№	model	precision	recall	f1	accuracy	roc_auc
0	Random Forest	0.825000	0.781250	0.777778	0.75	0.949684
1	Decision Tree	0.625000	0.708333	0.636111	0.60	0.781002
2	Logistic Regression	0.523810	0.593750	0.516484	0.50	0.814174
3	Gradient Boosting	0.379167	0.416667	0.388095	0.45	0.795573
4	Support Vector Machine	0.250000	0.333333	0.266667	0.50	0.686198
5	K-Nearest Neighbors	0.550000	0.447917	0.476068	0.45	0.718285
6	Random Forest	0.841667	0.802083	0.769444	0.75	0.921410
7	Decision Tree	0.684524	0.708333	0.661111	0.60	0.782738
8	Logistic Regression	0.489583	0.489583	0.482440	0.50	0.712736
9	Gradient Boosting	0.604167	0.645833	0.612500	0.65	0.857391
10	Support Vector Machine	0.250000	0.333333	0.266667	0.50	0.716518
11	K-Nearest Neighbors	0.550000	0.447917	0.476068	0.45	0.691251
12	Random Forest	0.775000	0.708333	0.691667	0.65	0.925781
13	Decision Tree	0.708333	0.708333	0.651471	0.65	0.792535
14	Logistic Regression	0.350000	0.375000	0.351923	0.40	0.580109
15	Gradient Boosting	0.750000	0.677083	0.656250	0.60	0.867188
16	Support Vector Machine	0.171875	0.260417	0.195833	0.40	0.758681
17	K-Nearest Neighbors	0.345779	0.343750	0.330297	0.45	0.694010
18	Random Forest	0.819444	0.781250	0.772549	0.75	0.914342
19	Decision Tree	0.585317	0.489583	0.515649	0.50	0.651538
20	Logistic Regression	0.494643	0.468750	0.472222	0.50	0.744296
21	Gradient Boosting	0.846591	0.781250	0.798496	0.75	0.945871
22	Support Vector Machine	0.216667	0.302083	0.243083	0.45	0.789621
23	K-Nearest Neighbors	0.619697	0.500000	0.532354	0.55	0.840588




Рис. 4. Графики ROC-кривых в оценке метрик сценариев сочетания ИП и фаз контрастирования МРТ-исследования при сравнении 6 моделей машинного обучения

Fig. 4. ROC curve plots in evaluating the metrics of scenarios of combination MRI sequences and enhancement phases when comparing 6 machine learning models

Радиомические модели были основаны на данных 88 пациентов, прошедших МРТ-исследование с гепатоспецифическим контрастным препаратом «Примовист». В модель вошли только артериальная, портальная и гепатобилиарная фазы контра-

стирования. При использовании на валидационной группе, дискриминативные способности модели в сочетании с клиническими данными составили AUC 0,938.

В ходе нашего научного эксперимента в первом случае полученные показатели продемонстрировали, что анализ средней важности в различных группах не может являться подходящим алгоритмом для включения или исключения какой-либо фазы контрастирования или ИП исследования. При тесте ANOVA различия между значимостью фаз контрастирования и последовательностями исследования оказались незначимыми. Соответственно, стратегия включения всех фаз с последующим отбором показателей либо сравнение каждой из моделей по показателям ROC AUC является наиболее подходящей.

Во втором эксперименте было получено, что гепатоспецифическая фаза обладает самыми высокими дискриминативными возможностями, однако при сочетании фаз контрастирования и ИП исследования, точность и другие метрики моделей повышаются.

Соответственно, наилучшей стратегией подбора дизайна исследования является максимальное включение рационально обоснованных показателей (фаз контрастирования и импульсных последовательностей исследования) в модели машинного обучения, а большее внимание исследователей должно быть сосредоточено на отборе значимых показателей внутри групп показателей различного рода, чем исключение отдельных групп показателей.

Такие же результаты показывают аналогичные исследования других авторов, в которых в качестве дополнительных показателей используют различного рода клинико-лабораторную информацию и анамнестические данные.

Выводы

При использовании различных радиомических моделей ГСФ МРТ-исследования показала наивысшие дискриминативные способности, однако, при сочетании большего количества фаз контрастирования и ИП МРТ-исследования показатели AUC незначительно снизились, но точность модели повысилась.

Учитывая способность моделей машинного обучения к поиску нелинейных связей и закономерностей в большом массиве данных, сочетание большего количества фаз контрастирования и последовательностей в одной модели значительно повышает ее дискриминативные способности, что позволит значительно улучшить уровень общей и дифференциальной диагностики ГЦР. Однако при добавлении большего количества фаз исследования следует учитывать увеличение временных и финансовых затрат, в связи с чем целесообразно придерживаться баланса между точностью и трудоемкостью исследования.

Список литературы / References

1. Global Burden of Disease Liver Cancer Collaboration, Akinyemiju T, Abera S, et al. The Burden of Primary Liver Cancer and Underlying Etiologies From 1990 to 2015 at the Global, Regional, and National Level: Results From the Global Burden of Disease Study 2015. *JAMA Oncol.* 2017;3(12):1683-91. <https://doi.org/10.1001/jamaoncol.2017.3055>
2. Forner A, Reig M, Bruix J. Hepatocellular carcinoma. *Lancet.* 2018;391(10127):1301-14. [https://doi.org/10.1016/S0140-6736\(18\)30010-2](https://doi.org/10.1016/S0140-6736(18)30010-2)
3. Каприн АД, Старинский ВВ, Шахзадова АО и др. Состояние онкологической помощи населению России в 2022 году. М.: МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России. 2022.
4. Кармазановский ГГ, Шантаревич МЮ, Сташкив ВИ и др. Воспроизводимость текстурных показателей КТ- и МРТ-изображений гепатоцеллюлярного рака. Медицинская визуализация. 2023;27(3):84-93. <https://doi.org/10.24835/1607-0763-1372>
Karmazanovsky GG, Shantarevich MY, Stashkiv VI, et al. Reproducibility of CT and MRI texture features of hepatocellular carcinoma. *Medical Visualization.* 2023;27(3):84-93. (In Russ.) <https://doi.org/10.24835/1607-0763-1372>
5. Marrero JA, Kulik LM, Sirlin CB, et al. Diagnosis, Staging, and Management of Hepatocellular Carcinoma: 2018 Practice Guidance by the American Association for the Study of Liver Diseases. *Hepatology.* 2018;68(2):723-50. <https://doi.org/10.1002/hep.29913>
6. EASL Clinical Practice Guidelines: Management of hepatocellular carcinoma. *J Hepatol.* 2018;69(1):182-236. <https://doi.org/10.1016/j.jhep.2018.03.019>
7. Motosugi U, Bannas P, Sano K, Reeder SB. Hepatobiliary MR contrast agents in hypovascular hepatocellular carcinoma. *J Magn Reson Imaging.* 2015;41(2):251-65. <https://doi.org/10.1002/jmri.24712>
8. Kierans AS, Fowler KJ, Chernyak V. LI-RADS in 2024: recent updates, planned refinements, and future directions. *Abdom Radiol (NY).* Published online December 13, 2024. <https://doi.org/10.1007/s00261-024-04730-w>
9. Кармазановский ГГ, Кондратьев ЕВ, Груздев ИС и др. Современная лучевая диагностика и интеллектуальные персонализированные технологии в гепатопанкреатологии. Вестник Российской академии медицинских наук. 2022;77(4):245-53.
Karmazanovsky GG, Kondratyev EV, Gruzdev IS, et al. Radiation diagnostics and intelligent personalized technologies in hepatopancreatology. *Vestnik Rossijskoj akademii nauk* 2022;77(4):245-53 (In Russ.) <https://doi.org/10.15690/vramn2053>
10. Mirestea CC, Pagute O, Buzea C, et al. Radiomic Machine Learning and Texture Analysis — New Horizons for Head and Neck Oncology. *Maedica (Bucur).* 2019;14(2):126-30. <https://doi.org/10.26574/maedica.2019.14.2.126>
11. Sagir Kahraman A. Radiomics in Hepatocellular Carcinoma. *J Gastrointest Cancer.* 2020;51(4):1165-8. <https://doi.org/10.1007/s12029-020-00493-x>
12. Masokano IB, Liu W, Xie S, Marcellin DFH, Pei Y, Li W. The application of texture quantification in hepatocellular carcinoma using CT and MRI: a review of perspectives and challenges. *Cancer Imaging.* 2020;20(1):67. <https://doi.org/10.1186/s40644-020-00341-y>
13. Молостова ЮВ, Медведева БМ, Кондратьев ЕВ и др. Возможности текстурного анализа и машинного обучения в МРТ-диагностике раннего ГЦР. Онкологический журнал: лучевая диагностика, лучевая терапия. 2024;7(4):68-73.

- Molostova IV, Medvedeva BM, Kondratyev EV et al. 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. (In Russ.).
<https://doi.org/10.37174/2587-7593-2024-7-4-68-73>
14. Navin PJ, Venkatesh SK. Hepatocellular Carcinoma: State of the Art Imaging and Recent Advances. *J Clin Transl Hepatol*. 2019;7(1):72-85.
<https://doi.org/10.14218/JCTH.2018.00032>
 15. Сташкив ВИ, Шантаревич МЮ, Кармазановский ГГ. Предикция степени дифференцировки гепатоцеллюлярного рака по данным текстурного анализа магнитно-резонансных томограмм. *Диагностическая и интервенционная радиология*, 2023;17(3 Приложение №1):48-57.
Stashkiv VI, Shantarevich MY, Karmazanovsky GG Prediction of the degree of differentiation of hepatocellular carcinoma using texture analysis of magnetic resonance imaging. *Diagnostic interventional & Radiology*. 2023;17(3№1):48-57. (In Russ.).
[https://doi.org/10.25512/DIR.2023.17.3\(1\).07](https://doi.org/10.25512/DIR.2023.17.3(1).07)
 16. Fedorov A, Beichel R, Kalpathy-Cramer J, et al. 3D Slicer as an image computing platform for the Quantitative Imaging Network. *Magn Reson Imaging*. 2012;30(9):1323-41.
<https://doi.org/10.1016/j.mri.2012.05.001>
 17. van Griethuysen JJM, Fedorov A, Parmar C, et al. Computational Radiomics System to Decode the Radiographic Phenotype. *Cancer Res*. 2017;77(21):e104-e107.
<https://doi.org/10.1158/0008-5472.CAN-17-0339>

Вклад авторов

Ю.В. Молостова: обзор публикаций по теме статьи, разработка дизайна исследования, сбор данных, написание текста рукописи.

Б.М. Медведева: разработка дизайна исследования, сбор данных.

Т.Г. Геворкян: разработка дизайна исследования, сбор данных.

Е.В. Кондратьев: разработка дизайна исследования, статистическая обработка

А.А. Усталов: разработка дизайна исследования, статистическая обработка

М.С. Новрузбеков: разработка дизайна исследования

О.Д. Олисов: разработка дизайна исследования

В.М. Тарнопольский: статистическая обработка

Authors' contributions

Iu.V. Molostova: review of publications, study design development, data collection, writing the text of manuscript.

B.M. Medvedeva: study design development, data collection.

T.G. Gevorkyan: study design development, data collection.

E.V. Kondratyev: study design development, statistical procession.

A.A. Ustalov: study design development, statistical procession.

M.S. Novruzbekov: study design development.

O.D. Olisov: study design development.

V.M. Tarnopolsky: statistical procession.

Information about the authors

Iuliia V. Molostova, <https://orcid.org/0000-0001-9692-116X>.

Bela M. Medvedeva, <https://orcid.org/0000-0003-1779-003X>.

Tigran G. Gevorkyan, <https://orcid.org/0009-0008-3486-302X>.

Andrey A. Ustalov, <https://orcid.org/0009-0005-9267-8584>.

Evgeny. V. Kondratyev, <https://orcid.org/0000-0001-7070-3391>.

Murad S. Novruzbekov, <https://orcid.org/0000-0002-6362-7914>.

Oleg D. Olisov, <https://orcid.org/0000-0002-0691-5581>.

Vitaly M. Tarnopolsky, <https://orcid.org/0009-0003-9361-8538>.

Финансирование. Это исследование было проведено со спонсорской поддержкой Аналитического центра при Правительстве Российской Федерации (Соглашение №. 70-2024-000121 dd 29.03.2024. IGK 000000D730324P540002). Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов. Соответствие принципам этики. Одобрение этического комитета не требовалось. Информированное согласие. Пациенты подписали информированное согласие на участие в исследовании.

Тип статьи: Оригинальная статья.

Поступила: 29.12.2024.

Принята к публикации: 17.02.2025.

Опубликована online: 26.03.2025.

Financing. This research has been financially supported by The Analytical Center for the Government of the Russian Federation (Agreement No. 70-2024-000121 dd 29.03.2024. IGK 000000D730324P540002). Conflict of interests. Not declared.

Ethical compliance. Ethical committee approval was not necessary.

Informed consent. Patients signed informed consent to participate in the study.

Article type: Original article.

Received: 29.12.2024.

Accepted for publication: 17.02.2025.

Published online: 26.03.2025.