

ВАЛИДАЦИЯ РАДИОМИЧЕСКОЙ МОДЕЛИ НА ОСНОВЕ ADC-КАРТ МРТ ДЛЯ ДИАГНОСТИКИ РАКА ПРЕДСТАТЕЛЬНОЙ ЖЕЛЕЗЫ

О.В. Крючкова^{1,2*}, Е.В. Щепкина^{3,4}, А.И. Кузнецов⁵, Е.В. Заря¹, С.В. Епифанова^{1,4},
С.М. Алферов¹, С.А. Левицкий¹

¹ ФГБУ «Центральная клиническая больница с поликлиникой» Управления делами Президента РФ, Москва

² ФГБУ ДПО «Центральная государственная медицинская академия» Управления делами Президента РФ, Москва

³ ФГБУ ВО «Российская академия народного хозяйства и государственной службы при Президенте РФ», Москва

⁴ ГБУЗ «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения г. Москвы», Москва

⁵ ФГБУ ВО «Московский авиационный институт (национальный исследовательский университет)», Москва

RADIOMIC MODEL VALIDATION BASED ON MRI ADC MAPS FOR PROSTATE CANCER DIAGNOSIS

O.V. Kryuchkova^{1,2*}, E.V. Schepkina^{3,4}, A.I. Kuznetsov⁵, E.V. Zarya¹, S.V. Epifanova^{1,4},
S.M. Alferov¹, S.A. Levitskii¹

¹ Central Clinical Hospital of Department of Presidential Affairs, Moscow, Russia

² Central State Medical Academy of Department of Presidential Affairs, Moscow, Russia

³ Russian Presidential Academy of National Economy and Public Administration – RANEPА, Moscow, Russia

⁴ Research and Practical Clinical Center for Diagnostics and Telemedical Technologies, Moscow, Russia

⁵ Moscow Aviation Institute (National Research University), Moscow, Russia

*E-mail: ovk16@bk.ru

Аннотация

Значительная доля рака предстательной железы (РПЖ) в структуре онкологической заболеваемости мужчин определяет актуальность совершенствования методов его диагностики. Перспективным направлением является радиомика – количественный анализ медицинских изображений. **Цель исследования** – провести валидацию радиомической модели на основе данных магнитно-резонансной томографии (МРТ) для дифференциации злокачественных и доброкачественных изменений предстательной железы. **Материалы и методы.** Проведено ретроспективное одноцентровое когортное исследование данных 123 пациентов. В исследовании участвовали мужчины в возрасте от 54 до 67 лет (средний возраст – 62 года). Обучающую и тестовую выборки составили 67 (54%) и 56 (46%) пациентов соответственно. На основе МРТ-изображений выполнен текстурный анализ ADC-карт. Для отбора признаков и построения модели использовали сравнительную статистику, метод RFE (Recursive Feature Elimination), многофакторную логистическую регрессию, дерево решений и комбинированное (Stacking) моделирование. **Результаты.** Валидируемая модель включала пять ключевых радиомических предикторов. На этапе обучения комбинированная (Stacking) модель показала точность – 94.2%, чувствительность – 92.3%, специфичность – 96.2%, ROC-AUC – 99.0%. На независимой тестовой выборке ее производительность составила: точность – 92.9%, чувствительность – 95.7%, специфичность – 80.0%, ROC-AUC – 95.2%. На основе модели создан калькулятор. **Заключение.** Валидированная радиомическая модель на основе ADC-карт МРТ демонстрирует высокую и стабильную диагностическую эффективность в дифференциации злокачественных и доброкачественных изменений предстательной железы.

Ключевые слова: рак предстательной железы, магнитно-резонансная томография, радиомика, машинное обучение, диагностическая точность, прогностическая модель, текстурный анализ.

Abstract

A significant portion of prostate cancer (PCa) in the structure of oncological morbidity among males determines the importance of improving its diagnostic modalities. Radiomics, a quantitative analysis of medical images, is a promising direction in this field. **Purpose.** To validate the radiomics model based on MRI data for differentiating malignant and benign prostate lesions. **Materials and methods.** 123 patients were enrolled in a retrospective single-center cohort study. They aged 62 (54–67) years. The training and test sets comprised 67 (54%) and 56 (46%) patients, respectively. A texture analysis of ADC maps was made using MRI images. For signs selection and model building, comparative statistics, RFE (Recursive Feature Elimination) method, multivariate logistic regression, decision tree, and combined (Stacking) modeling were used. **Results.** The validated model includes five key radiomic predictors. At the training stage, the combined (Stacking) model showed accuracy of 94.2%, sensitivity of 92.3%, specificity of 96.2%, and ROC-AUC of 99.0%. At the independent test set, its performance was: accuracy 92.9%, sensitivity 95.7%, specificity 80.0%, ROC-AUC 95.2%. A calculator was created based on the model. **Conclusion.** The validated radiomics model, which uses MRI ADC maps, demonstrates high and stable diagnostic efficacy in differentiating malignant and benign prostate lesions.

Keywords: prostatic neoplasms, magnetic resonance imaging, radiomics, machine learning, diagnostic accuracy, predictive model, texture analysis.

Ссылка для цитирования: Крючкова О.В., Щепкина Е.В., Кузнецов А.И., Заря Е.В., Епифанова С.В., Алферов С.М., Левицкий С.А. Валидация радиомической модели на основе ADC-карт МРТ для диагностики рака предстательной железы. *Кремлевская медицина. Клинический вестник*. 2026; 1: 55–61.

Введение

Согласно эпидемиологическим данным, на долю рака предстательной железы (РПЖ) в России приходится 20.7% всех случаев онкологической патологии у мужчин, что соответствует примерно 66 695 новым диагнозам в 2024 г. [1], что обуславливает важность точного и своевременного выявления этого заболевания. Дифференцировка доброкачественных и злокачественных форм имеет решающее значение для определения соответствующего лечения и улучшения показателей выживаемости.

Существующая диагностика РПЖ далека от идеальной, что подтверждается многочисленными исследованиями, сосредоточенными на анализе факторов риска при диагностике рака предстательной железы и поиске новых диагностических маркеров [2, 3]. Например, было выявлено, что прогностическая ценность возраста как фактора риска удовлетворительна – ROC-AUC – 69% [4]. Значение простатспецифического антигена (ПСА) или его модификации, такие как плотность ПСА (PSAD), общий ПСА (tPSA) или свободный ПСА (fPSA), может предсказывать наличие РПЖ с точностью ROC-AUC – 62.3–86.1% [5–11]; для объема простаты ROC-AUC – 62.5–68% [4, 10, 11]; для пальцевого ректального исследования (ПРИ; Digital Rectal Examination, DRE) ROC-AUC – 61.7% [9]. На сегодняшний день мультипараметрическая МРТ (мпМРТ) предстательной железы является наиболее информативным и флагманским методом визуализации в диагностике РПЖ. Точность категории PI-RADS, установленной по результатам МРТ, также вариабельна: ROC-AUC – 65–85.9% [5, 9, 12–14]. При этом следует понимать, что система PI-RADS напрямую зависит от опыта и мнения рентгенолога, анализирующего МРТ-изображения [15]. Таким образом, существует потребность в разработке автоматизированной системы, которая сможет обеспечить большую надежность в диагностике РПЖ, что может быть достигнуто, в том числе, в рамках МРТ-радиомики [16].

В последние годы в научных публикациях появляется много описаний многофакторных моделей прогнозирования РПЖ. К ним относятся прогностические модели, построенные как с использованием только клинических данных (ROC-AUC – 73.8–74% [17, 18]) или только радиомических данных (ROC-AUC – 58–98.9% [7, 8, 11, 16–25]), так и смешанные модели, построенные на основе клинических и радиомических данных (ROC-AUC – 80–93.7% [5, 6, 9, 10, 13, 17, 22, 27, 28]).

Наибольшее распространение в качестве основы для радиомических предикторов получили МРТ-протоколы, включающие T2-взвешенные изображения и карты ADC [29].

Хотя расчетные ROC-AUC некоторых моделей кажутся идеальными, все модели оцениваются как имеющие высокий риск систематической ошибки, главным образом из-за высокого риска переобучения модели и отсутствия их валидации на реальных данных. Более того, многие описания моделей расплывчаты. Проведенный нами систематический обзор подтвердил эти

опасения [29]: несмотря на многообещающие результаты (совокупная ROC-AUC – 0.793), большинство исследований страдают методологическими недостатками – независимая тестовая выборка использовалась лишь в 43% работ, а коррекция дисбаланса классов и проверка на мультиколлинеарность применялись в единичных случаях (10 и 29% соответственно). Сходные ограничения (малый размер выборки, одноцентровой дизайн, ретроспективный характер данных) выявлены и в независимом систематическом обзоре Mohammadi и соавт. [2], что подчеркивает системный характер проблемы ограниченной обобщаемости прогностических моделей в диагностике РПЖ.

Преодоление указанных ограничений возможно благодаря применению методологий машинного обучения, позволяющих извлекать скрытые закономерности из многомерных данных. Применение различных алгоритмов, адаптированных к типам и структуре имеющихся данных, позволяет получить более объективное и глубокое представление об их ключевых свойствах, выявить скрытые закономерности и установить значимые взаимосвязи [30]. Исходя из этого, одной из наиболее важных областей применения является прогностический анализ, который включает в себя выявление особенностей (функций, относящихся к индивидуальным характеристикам данных) на основе машинного обучения, создание моделей с помощью статистического анализа, а затем обработку новых (независимых) данных полученной прогностической моделью [31].

Цель исследования – провести валидацию радиомической модели на основе данных МРТ для дифференциации злокачественных и доброкачественных изменений предстательной железы.

Ранее нами была спроектирована и исследована прогностическая модель вероятности наличия рака предстательной железы, которая протестирована не только на обучающей, но и на тестовой выборке с оценкой ее чувствительности, специфичности и ROC-AUC. Для построения модели использовали алгоритм машинного обучения (многофакторная логистическая регрессия), который создает легко интерпретируемую модель с открытой формулой. Таким образом, ключевым достоинством алгоритма стала не только его предсказательная сила, но и прозрачность – возможность понять, какие именно признаки и с каким весом привели к конкретному прогнозу, что принципиально важно для доверия к модели и ее внедрения в клиническую практику.

Материалы и методы

На этапе валидации использован дизайн одноцентрового ретроспективного когортного исследования. Проанализированы данные пациентов с клиническим подозрением на РПЖ в период с 2017 по 2023 г. Все обследования выполняли на МР-томографе по стандартному протоколу, соответствующему рекомендациям PI-RADS версии 2.1. Для последующего текстурного анализа использовали исключительно параметрические карты измеряемого коэффициента диффузии (ИКД).

На этих картах экспертами-рентгенологами вручную размечались трехмерные области интереса (ROI), из которых с помощью программного пакета LIFEx версии X было экстрагировано 96 количественных радиомических признаков. Окончательный диагноз (исход) во всех случаях подтверждался гистологическим заключением после радикальной простатэктомии или биопсии. Из 123 пациентов, включенных в анализ, у 103 (83.7%) был подтвержден РПЖ, у 20 (16.3%) результат был отрицательным (PI-RADS \leq 2).

Критерии отбора

Критериями включения в исследование служили: возраст \geq 18 лет; наличие гистологически верифицированного диагноза РПЖ; полный набор данных мпМРТ, выполненной не ранее чем за шесть месяцев до оперативного вмешательства и до проведения биопсии. Из исследования исключались пациенты с синхронными злокачественными новообразованиями, получавшие какой-либо вид противоопухолевой терапии (лучевую, гормональную, химиотерапию) до момента МРТ, а также те, у кого качество МРТ-изображений было признано неудовлетворительным.

Предобработка данных и формирование выборок

Первоначальный набор данных был случайным образом разделен на обучающую ($n = 67$) и тестовую ($n = 56$) подвыборки. Процедуры предобработки применяли к обучающему набору. Из анализа были исключены признаки, доля пропущенных значений в которых превышала 30% (49 из 96). Отсутствующие значения в оставшихся признаках заполняли с использованием алгоритма K-ближайших соседей (KNN). Для выявления и коррекции выбросов применяли построение блочных диаграмм (box-plot) с использованием межквартильного размаха (IQR).

Статистический анализ и отбор переменных

Все вычисления проводили в среде Python v.3.12. Проверка распределения количественных переменных критерием Шапиро – Уилка показала их отклонение от нормальности, в связи с чем для описания данных использовали медиану с квантилями (Me (Q1–Q3)), а для сравнения групп – непараметрический критерий Манна – Уитни. Категориальные переменные сравнивали с помощью критерия χ^2 или точного критерия Фишера. Уровень статистической значимости был установлен на отметке $p < 0.05$.

Для первичного отбора признаков, ассоциированных с наличием РПЖ, использовали описанные методы сравнения групп. Затем между отобранными признаками проводили корреляционный анализ (коэффициент Спирмена), и в случае сильной корреляции ($r > 0.7$) одну из переменных пары исключали. На заключительном этапе для формирования финального набора предикторов, обладающих максимальной совместной прогностической силой относительно клинического исхода, был применен метод рекурсивного исключения признаков (Recursive Feature Elimination, RFE).

Построение и тестирование моделей

Разработку моделей осуществляли на основе двух интерпретируемых методов машинного обучения – многофакторной логистической регрессии (МЛР) и деревьев

решений (ДР). Для борьбы с дисбалансом классов техника SMOTE (Synthetic Minority Over-sampling Technique) была применена строго к обучающей выборке после ее формирования и до этапа обучения моделей.

Оптимизацию гиперпараметров моделей осуществляли методом поиска по сетке в сочетании с пятикратной перекрестной проверкой (5-fold cross-validation), целью которой была максимизация ROC-AUC.

Помимо индивидуальных моделей, для последующей валидации была создана комбинированная модель (Stacking), в которой итоговый прогноз формировался как среднее арифметическое вероятностей, предсказанных моделями МЛР и ДР.

Оценку рабочих характеристик построенных моделей проводили по комплексу стандартных метрик: точности (accuracy), чувствительности (sensitivity), специфичности (specificity) и площади под ROC-кривой (ROC-AUC). Для определения устойчивости полученных оценок был рассчитан 95%-ный доверительный интервал методом бутстрепа на основе 1000 итераций. Анализ потенциальной клинической пользы от внедрения итоговой модели выполняли посредством построения кривой принятия решений (Decision Curve Analysis, DCA).

При описании методологии и результатов использовали требования руководства TRIPOD (Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis Or Diagnosis), что обеспечило полноту и прозрачность отчетности на всех этапах исследования [32, 33]. В связи с ретроспективным характером работы

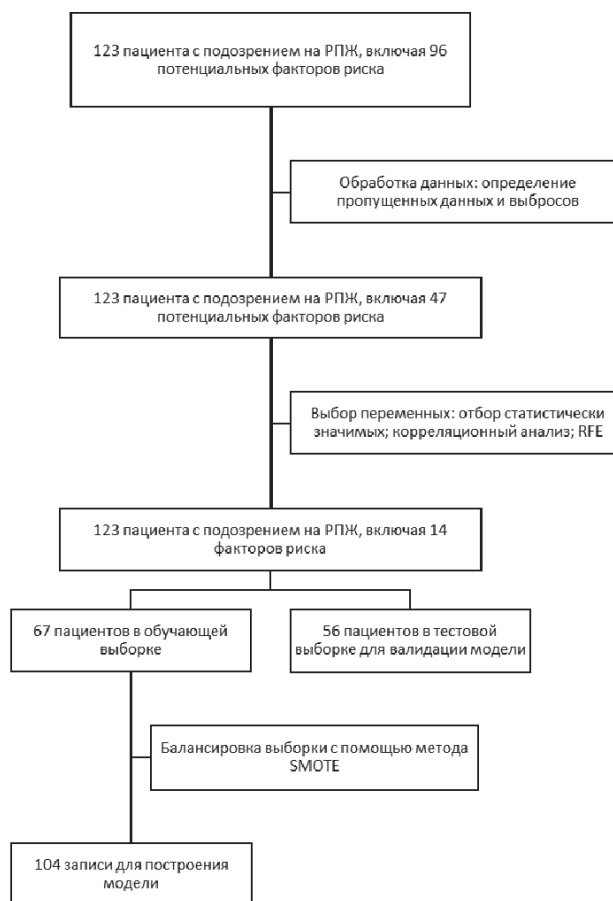


Рис. 1. Блок-схема общего процесса проведения исследования

Сравнение метрик качества моделей на обучающей выборке, %

Метрика оценки	МЛР	Дерево решений	Stacking
ROC-AUC	86.7 (80.8; 92.2)	98.4 (96.3; 99.8)	99.0 (97.7; 100.0)
Точность	80.8 (75.0; 87.5)	89.4 (84.6; 94.2)	94.2 (90.4; 98.1)
Чувствительность	80.8 (71.7; 89.1)	80.8 (71.7; 89.3)	92.3 (86.2; 98.1)
Специфичность	80.8 (71.9; 89.6)	98.1 (94.2; 100.0)	96.2 (91.5; 100.0)

Таблица 2

Информативность итоговой (Stacking) модели на этапах обучения и тестирования, %

Критерии качества модели	Этап обучения, n = 67	Этап тестирования, n = 56
ROC-AUC	99.0 (97.7; 100.0)	95.2 (88.9; 100.0)
Точность	94.2 (90.4; 98.1)	92.9 (87.5; 98.2)
Чувствительность	92.3 (86.2; 98.1)	95.7 (90.5; 100.0)
Специфичность	96.2 (91.5; 100.0)	80.0 (60.0; 100.0)

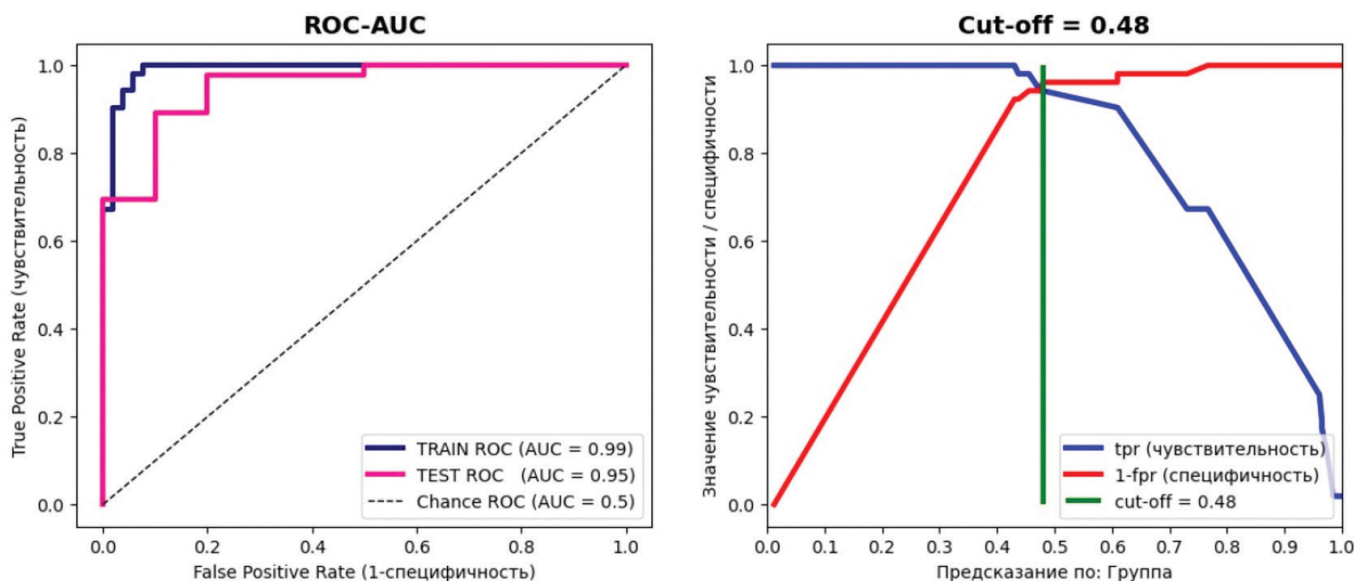


Рис. 2. ROC-AUC и cut-off (точка отсечения)

получения информированного согласия от пациентов не требовалась, поскольку все данные были обезличены.

Результаты

Ретроспективно были проанализированы 123 пациента с подозрением на РПЖ, в том числе 103 (83.7%) с РПЖ и 20 (16.3%) без РПЖ.

В исследовании участвовали мужчины в возрасте от 54 до 67 лет (средний возраст 62 года). Группы обучения и тестирования статистически значимо не различались по возрастному показателю ($p = 0.110$). Блок-схема общего процесса проведения исследования представлена на рис. 1.

В ходе сравнительного анализа были определены факторы риска, статистически значимо ($p < 0.05$) различающиеся между группами с РПЖ и без РПЖ (табл. 1). После проверки на мультиколлинеарность (коэффициент Спирмена (R_s) < 0.7) и последовательного применения метода RFE были сформированы финальные наборы признаков для построения моделей.

На следующем этапе были последовательно построены три модели:

1. Модель на основе МЛР. В финальную модель вошли

три предиктора: PARAMS ZSpatialResampling, SHAPE Sphericity[onlyFor3DROI] и GLRLM RLNU.

2. Модель на основе ДР. Алгоритм отобрал четыре ключевых признака: DISCRETIZED HISTO Entropy log10, SHAPE Sphericity[onlyFor3DROI], PARAMS ZSpatialResampling и GLRLM SRE.

3. Комбинированная модель Stacking. Для итоговой валидации была создана объединенная модель, усредняющая прогнозы МЛР и ДР. Ее финальный набор включает пять уникальных радиомических предикторов, представляющих собой объединение отобранных для МЛР и ДР признаков.

Сравнительные метрики всех трех моделей на обучающей выборке представлены в табл. 1.

Валидация на независимой выборке

Комбинированная модель Stacking, признанная оптимальной, была протестирована на независимой выборке из 56 пациентов. Пороговое значение вероятности для бинарной классификации было сохранено на уровне > 0.48 , определенное на ROC-кривой обучающей выборки как точка оптимального баланса между чувствительностью и специфичностью (максимальный

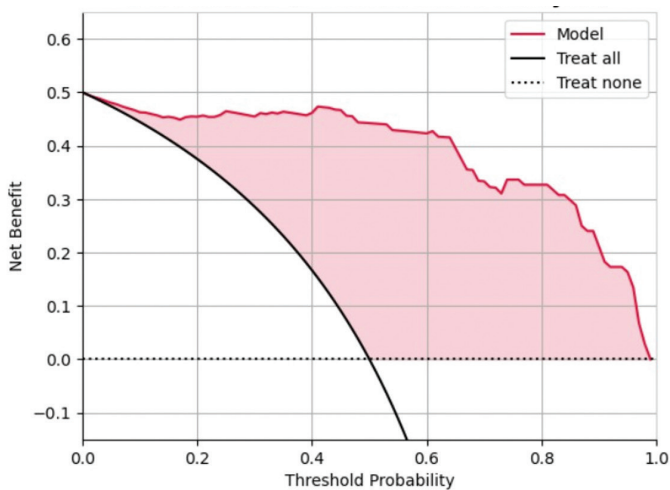


Рис. 3. Кривая принятия решений (DCA) для модели Stacking

индекс Юдена). Это значение было использовано для оценки классификационной способности модели, тогда как для анализа клинической полезности (DCA) рассматривали непрерывный диапазон порогов. Модель продемонстрировала стабильно высокую производительность (табл. 2).

Оптимальное пороговое значение (cut-off) для модели визуализировано на рис. 2.

Таким образом, итоговая модель, основанная на пяти радиомических предикторах, показала ROC-AUC – 95.2% на независимых данных, что в соответствии с общепринятыми качественными критериями соответствует характеристикам модели высокого качества (AUC > 90%). Анализ кривой принятия решений (рис. 3) демонстрирует теоретическую клиническую полезность модели, показывая в каком диапазоне пороговых вероятностей ее использование для стратификации пациентов могло бы принести чистую пользу по сравнению со стратегиями «биопсия всем» или «биопсия никому». Данный анализ визуализирует потенциальное влияние диагностических характеристик модели на принятие решений в заданном клиническом контексте.

Обсуждение

Согласно данным проведенного нами систематического обзора и метаанализа [29], включавшего 73 прогностические модели, эффективность алгоритмов машинного обучения в диагностике РПЖ существенно различается: множественная логистическая регрессия (MLR) показала стабильно высокие результаты (ROC-AUC – 85.2%), модели на основе деревьев решений (DT) – несколько ниже (ROC-AUC – 75.5%), а сверточные нейросети (CNN), несмотря на высокую точность (ROC-AUC – 85.6%), продемонстрировали значительную гетерогенность ($I^2 = 95.75\%$) и относятся к категории «черных ящиков» с низкой интерпретируемостью [4–8, 12, 13, 17, 19–23, 28, 35–40].

В рамках настоящей работы индивидуальные модели множественной логистической регрессии и дерева решений продемонстрировали показатели, которые соответствуют или превосходят средние по выборке литературные данные (ROC-AUC – 86.7 и 98.4% соот-

ветственно). Ключевым результатом данного исследования можно считать валидацию комбинированной (Stacking) модели.

На предложенную формулу прогнозирования получен патент на изобретение Российской Федерации № 2839227 от 28.04.2025 (заявка № 2024111956 от 11.07.2024) [40]. Объединение сильных сторон двух интерпретируемых алгоритмов в рамках валидируемой модели позволило не только получить высокие показатели на обучающей выборке (ROC-AUC – 99.0%), но и подтвердить высокую эффективность (ROC-AUC – 95.2%) на независимой тестовой когорте. Это свидетельствует о низком уровне переобучения и общей стабильности модели. Для практического применения на основе валидированной модели был запрограммирован калькулятор [41].

Высокие диагностические характеристики валидированной модели позволяют рассматривать ее в качестве потенциального инструмента для объективной, неинвазивной дифференциальной диагностики очаговых изменений предстательной железы. В перспективе, после проведения дальнейших проспективных исследований, подобный инструмент мог бы быть использован для стратификации пациентов с подозрением на РПЖ при принятии решения о целесообразности выполнения биопсии. Такой подход, интегрированный в стандартный протокол МРТ (без необходимости контрастного усиления), способен потенциально повысить точность догоспитальной диагностики.

Ограничения исследования связаны с его ретроспективным и одноцентровым дизайном, что может влиять на обобщаемость результатов.

Заключение

В результате исследования была проведена валидация радиомической модели для дифференциальной диагностики РПЖ на основе анализа карт ИКД МРТ-изображений. Модель включает пять ключевых предикторов – DISCRETIZED HISTO Entropy log10, SHAPE Sphericity[onlyFor3DROI], PARAMS ZSpatialResampling, GLRLM SRE, GLRLM RLNU – и демонстрирует высокое качество (ROC-AUC – 95.2%) на независимой выборке.

Валидированный алгоритм, реализованный в виде программного обеспечения, представляет собой готовый инструмент для дальнейшего клинического тестирования. Его потенциальное применение позволит повысить объективность и точность неинвазивной диагностики РПЖ, особенно в условиях ограниченных ресурсов, так как не требует модификации стандартных протоколов МРТ или использования контрастных препаратов.

Литература

1. Злокачественные новообразования в России в 2024 году (заболеваемость) / под ред. А.Д. Каприна и др. – М.: МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России. – 2025. – С. 178. [Malignant neoplasms in Russia in 2024 (incidence) / ed. A.D. Kaprin et al. – Moscow: P.A. Herzen Moscow Oncology Research Institute – a branch of the National Medical Research Center of Radiology. – 2025. – P. 178. In Russian].

2. Mohammadi S. et al. Identification of factors affecting prostate cancer using machine learning methods: a systematic review // *Asian Pac. J. Cancer Prev.* – 2025. – V. 26. – No 5. – P. 1519–1528. DOI: 10.31557/APJCP.2025.26.5.1519.
3. Hloušek S. et al. Genetic and non-genetic risk factors in prostate cancer: towards a precision medicine approach // *Folia Biol. (Praha)*. – 2025. – V. 71. – No 3. – P. 95–108. DOI: 10.14712/fb2025071030095.
4. Liu J. et al. Using clinical parameters to predict prostate cancer and reduce the unnecessary biopsy among patients with PSA in the gray zone // *Sci. Rep.* – 2020. – V. 10. – No 1. – P. 5157. DOI: 10.1038/s41598-020-62015-w.
5. Han L. et al. Combining magnetic resonance diffusion-weighted imaging with prostate-specific antigen to differentiate between malignant and benign prostate lesions // *Med. Sci. Monit.* – 2022. – V. 28. – P. e936798. DOI: 10.12659/MSM.935307.
6. Ayyad S.M. et al. A New Framework for Precise Identification of Prostatic Adenocarcinoma // *Sensors (Basel)*. – 2022. – V. 22. – No 5. – P. 1848. DOI: 10.3390/s22051848.
7. Jin P. et al. Machine learning-based radiomics model to predict benign and malignant PI-RADS v2.1 category 3 lesions: a retrospective multi-center study // *BMC Med. Imaging*. – 2023. – V. 23. – No 1. – P. 47. DOI: 10.1186/s12880-023-01002-9.
8. Lu Y. et al. Biparametric MRI-based radiomics classifiers for the detection of prostate cancer in patients with PSA serum levels of 4–10 ng/mL // *Front. Oncol.* – 2022. – V. 12. – P. 1020317. DOI: 10.3389/fonc.2022.1020317.
9. Woźnicki P. et al. Multiparametric MRI for Prostate Cancer Characterization: Combined Use of Radiomics Model with PI-RADS and Clinical Parameters // *Cancers (Basel)*. – 2020. – V. 12. – No 7. – P. 1767. DOI: 10.3390/cancers12071767.
10. Zheng S. et al. The roles of MRI-based prostate volume and associated zone-adjusted prostate-specific antigen concentrations in predicting prostate cancer and high-risk prostate cancer // *PLoS One*. – 2019. – V. 14. – No 11. – P. e0218645. DOI: 10.1371/journal.pone.0218645.
11. Kan Y. et al. Clinico-radiological characteristic-based machine learning in reducing unnecessary prostate biopsies of PI-RADS 3 lesions with dual validation // *Eur. Radiol.* – 2020. – V. 30. – No 11. – P. 6274–6284. DOI: 10.1007/s00330-020-06958-8.
12. Zhong J.-G. et al. Predicting prostate cancer in men with PSA levels of 4–10 ng/mL: MRI-based radiomics can help junior radiologists improve the diagnostic performance // *Sci. Rep.* – 2023. – V. 13. – No 1. – P. 4846. DOI: 10.1038/s41598-023-31869-1.
13. Li M. et al. Use of Radiomics to Improve Diagnostic Performance of PI-RADS v2.1 in Prostate Cancer // *Front. Oncol.* – 2021. – V. 10. – P. 631831. DOI: 10.3389/fonc.2020.631831.
14. Dikaios N. et al. Multi-parametric MRI zone-specific diagnostic model performance compared with experienced radiologists for detection of prostate cancer // *Eur. Radiol.* – 2019. – V. 29. – No 8. – P. 4150–4159. DOI: 10.1007/s00330-018-5799-y.
15. Rosenkrantz A.B. et al. Interobserver Reproducibility of the PI-RADS Version 2 Lexicon: A Multicenter Study of Six Experienced Prostate Radiologists // *Radiology*. – 2016. – V. 280. – No 3. – P. 793–804. DOI: 10.1148/radiol.2016152542.
16. Liu L. et al. Computer-aided Detection of Prostate Cancer with MRI // *Acad. Radiol.* – 2016. – V. 23. – No 8. – P. 1024–1046. DOI: 10.1016/j.acra.2016.03.010.
17. Gui S. et al. Application Value of Radiomic Nomogram in the Differential Diagnosis of Prostate Cancer and Hyperplasia // *Front. Oncol.* – 2022. – V. 12. – P. 859625. DOI: 10.3389/fonc.2022.859625.
18. Ma L. et al. Texture analysis based on PI-RADS 4/5-scored magnetic resonance images combined with machine learning to distinguish benign lesions from prostate cancer // *Transl. Cancer Res.* – 2022. – V. 11. – No 5. – P. 1146–1161. DOI: 10.21037/tcr-21-2271.
19. Jamshidi G. et al. Radiomics-based machine-learning method to diagnose prostate cancer using mp-MRI: a comparison between conventional and fused models // *Magn. Reson. Mater. Phys.* – 2022. – V. 36. – No 1. – P. 55–64. DOI: 10.1007/s10334-022-01037-z.
20. Aussavavirojekul P. et al. Optimization of clinical risk-factor interpretation and radiological findings with machine learning for PIRADS category 3 patients // *Prostate*. – 2022. – V. 82. – No 2. – P. 235–244. DOI: 10.1002/pros.24266.
21. Viswanath S.E. et al. Comparing radiomic classifiers and classifier ensembles for detection of peripheral zone prostate tumors on T2-weighted MRI: a multi-site study // *BMC Med. Imaging*. – 2019. – V. 19. – No 1. – P. 22. DOI: 10.1186/s12880-019-0308-6.
22. Ji X. et al. Bi-parametric magnetic resonance imaging based radiomics for the identification of benign and malignant prostate lesions: cross-vendor validation // *Phys. Eng. Sci. Med.* – 2021. – V. 44. – No 3. – P. 745–754. DOI: 10.1007/s13246-021-01022-1.
23. McGarry S.D. et al. Gleason Probability Maps: A Radiomics Tool for Mapping Prostate Cancer Likelihood in MRI Space // *Tomography*. – 2019. – V. 5. – No 1. – P. 127–134. DOI: 10.18383/j.tom.2018.00033.
24. Fernandes C.D. et al. Radiomic combination of spatial and temporal features extracted from DCE-MRI for prostate cancer detection. 2021 43rd // *Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. – 2021. – P. 3153–3156. DOI: 10.1109/EMBC46164.2021.9630015.
25. Chen Q. et al. A Transfer learning approach for malignant prostate lesion detection on multiparametric MRI // *Technol. Cancer Res. Treat.* – 2019. – V. 18. – P. 153303381985836. DOI: 10.1177/1533033819858363.
26. Maas M.C. et al. A Single-arm, multicenter validation study of prostate cancer localization and aggressiveness with a quantitative multiparametric magnetic resonance imaging approach // *Invest. Radiol.* – 2019. – V. 54. – No 7. – P. 437–447. DOI: 10.1097/RLI.0000000000000558.
27. Hu L. et al. Advanced zoomed diffusion-weighted imaging vs. full-field-of-view diffusion-weighted

- imaging in prostate cancer detection: a radiomic features study // *Eur. Radiol.* – 2021. – V. 31. – No 3. – P. 1760–1769. DOI: 10.1007/s00330-020-07227-4.
28. Ou Y.C. et al. Building a nomogram for prediction of prostate cancer in patients with preoperatively suspected prostate cancer // *Anticancer Res.* – 2020. – V. 40. – No 5. – P. 2995–3002. DOI: 10.21873/anticancer.14280.
29. Крючкова О.В. и др. Диагностическая точность искусственного интеллекта для скрининга рака предстательной железы при бипараметрической магнитно-резонансной томографии: систематический обзор // *Digital Diagnostics.* – 2024. – Т. 5. – № 3. – С. 534–550. [Kryuchkova O.V. et al. Diagnostic accuracy of artificial intelligence for the screening of prostate cancer in biparametric magnetic resonance imaging: a systematic review // *Digital Diagnostics.* – 2024. – V. 5. – No 3. – 534–550. In Russian]. DOI: 10.17816/DD626643.
30. Zampieri F.G. et al. ICU staffing feature phenotypes and their relationship with patients' outcomes: an unsupervised machine learning analysis // *Intensive Care Med.* – 2019. – V. 45. – No 1. – P. 1599–1607. DOI: 10.1007/s00134-019-05790-z.
31. Zack J.E. et al. Effect of an education program aimed at reducing the occurrence of ventilator-associated pneumonia // *Crit. Care Med.* – 2002. – V. 30. – No 11. – P. 2407–2412. DOI: 10.1097/00003246-200211000-00001.
32. Щепкина Е.В. и др. STARD и TRIPOD: рекомендации по предоставлению результатов диагностических и прогностических исследований. Практические советы для оформления статей в журналы // *Педиатрия. Журнал им. Г.Н. Сперанского.* – 2022. – Т. 101. – № 1. – С. 236–249. [Schepkina E.V. et al. STARD and TRIPOD: recommendations for the provision of diagnostic and prognostic research results. Practical advice for submitting articles to journals // *Pediatrics. Journal named after G.N. Speransky.* – 2022. – V. 101. – No 1. – P. 236–249. In Russian]. DOI: 10.24110/0031-403X-2022-101-1-236-249.
33. Moons K.G.M. et al. Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis (TRIPOD): Explanation and Elaboration // *Ann. Intern. Med.* – 2015. – V. 162. – No 1. – P. 1–73. DOI: 10.7326/M14-0698.
34. Zhou B. et al. Differentiation of prostate cancer and stromal hyperplasia in the transition zone with monoexponential, stretched-exponential diffusion-weighted imaging and diffusion kurtosis imaging in a reduced number of b values: correlation with whole-mount pathology // *J. Comput. Assist. Tomogr.* – 2022. – V. 46. – No 4. – P. 545–550. DOI: 10.1097/RCT.0000000000001314.
35. Wu M. et al. Transition zone prostate cancer: Logistic regression and machine-learning models of quantitative ADC, shape and texture features are highly accurate for diagnosis // *J. Magn. Reson. Imaging.* – 2019. – V. 50. – No 3. – P. 940–950. DOI: 10.1002/jmri.26674.
36. Li S. et al. A dynamic-static combination model based on radiomics features for prostate cancer using multiparametric MRI // *Phys. Med. Biol.* – 2023. – V. 68. – No 1. – P. 015008. DOI: 10.1088/1361-6560/aca954.
37. Chen T. et al. Prostate Cancer Differentiation and Aggressiveness: Assessment with a Radiomic-Based Model vs. PI-RADS v2 // *J. Magn. Reson. Imaging.* – 2019. – V. 49. – No 3. – P. 875–884. DOI: 10.1002/jmri.26243.
38. He D. et al. MRI-based radiomics models to assess prostate cancer, extracapsular extension and positive surgical margins // *Cancer Imaging.* – 2021. – V. 21. – No 1. – P. 46. DOI: 10.1186/s40644-021-00416-4.
39. Giambelluca D. et al. PI-RADS 3 Lesions: Role of Prostate MRI Texture Analysis in the Identification of Prostate Cancer // *Curr. Probl. Diagn. Radiol.* – 2021. – V. 50. – No 2. – P. 175–185. DOI: 10.1067/j.cpradiol.2019.10.009.
40. Патент на изобретение № 2839227, 28.04.2025. Заявка от 11.07.2024 / Крючкова О.В., Щепкина Е.В., Кузнецов А.И. Способ прогнозирования ЗНО на основе бпМРТ-радиомики. [Patent for invention No 2839227, 28.04.2025. Application: 11.07.2024. Kryuchkova O.V., Schepkina E.V., Kuznetsov A.I. Method for predicting probability of detecting prostate cancer in males based on MRI radiomics. In Russian]. URL: <https://www1.fips.ru/ofpstorage/Doc/IZPM/RUNWC1/000/000/002/839/227/ИЗ-02839227-00001/document.pdf>.
41. Свидетельство о регистрации программы для ЭВМ № 2023669718 от 19.09.2023 / Щепкина Е.В., Крючкова О.В., Кузнецов А.И. Программное обеспечение для прогнозирования вероятности выявления злокачественных новообразований (рака) предстательной железы у мужчин на основе МРТ-радиомики. [Certificate of registration of a computer program No 2023669718, 19.09.2023 / Schepkina E.V., Kryuchkova O.V., Kuznetsov A.I. Software for predicting the probability of detecting malignant neoplasms (cancer) of the prostate gland in men based on MRI radiomics. In Russian]. URL: <https://www.elibrary.ru/item.asp?id=54657407>.