

Разработка системы на базе глубокого обучения для помощи в принятии врачебных решений в определении оценок по системе PI-RADS: международное многоцентровое исследование

He Mingze¹, М.Э. Еникеев¹, Р.Т. Рзаев², И.М. Черненко¹, М.В. Фельдшер², Li He³, Hu Kebang⁴,
Е.В. Шпоть¹, Л.М. Рапопорт¹, П.В. Глыбочко¹

¹Институт урологии и репродуктивного здоровья человека ФГАОУ ВО Первый Московский государственный медицинский университет им. И.М. Сеченова Минздрава России (Сеченовский Университет); Россия, 119435 Москва, ул. Большая Пироговская, 2, стр. 1;

²отделение лучевой диагностики Университетской клинической больницы № 2 ФГАОУ ВО Первый Московский государственный медицинский университет им. И.М. Сеченова Минздрава России (Сеченовский Университет); Россия, 119435 Москва, ул. Большая Пироговская, 6, стр. 1;

³отделение лучевой диагностики, Первая больница Цзилиньского университета; Китай, Чанчунь;

⁴отделение урологии, Первая больница Цзилиньского университета; Китай, Чанчунь

Контакты: He Mingze hemingze97@gmail.com

Введение. Проведение мультипараметрической магнитно-резонансной томографии предстательной железы широко рекомендуется в клинической практике перед выполнением биопсии предстательной железы. Система отчетности данных магнитно-резонансной томографии предстательной железы (Prostate Imaging Reporting and Data System, PI-RADS) является стандартным инструментом для диагностики и принятия врачебных решений. Однако точный анализ данных мультипараметрической магнитно-резонансной томографии требует высокой экспертности, и трудоемкий, когнитивно насыщенный процесс часто снижает согласованность оценок между разными специалистами и у одного и того же специалиста.

Цель исследования – разработка системы компьютерной диагностики на базе глубокого обучения (DL-CAD) для минимизации влияния ручной сегментации на определение оценок PI-RADS.

Материалы и методы. С января 2020 г. по май 2024 г. ретроспективно отобраны 108 пациентов с гистологически подтвержденным раком предстательной железы с оценками PI-RADS 4–5 для разработки модели и тренировки. Для валидации модели были включены 28 доброкачественных случаев. Различные зоны предстательной железы были помечены в соответствии с руководствами PI-RADS v2.1 для облегчения выбора модели. Ручная сегментация областей предстательной железы и поражений выполнена на T2-взвешенных последовательностях, и была реализована архитектура 3D U-Net для модели глубокого обучения с использованием фреймворка MONAI. Диагностическая эффективность оценивалась с помощью статистического анализа на Python.

Результаты. Система DL-CAD показала среднюю точность 78 %, чувствительность 60 % и специфичность 84 % при обнаружении поражений. Коэффициент сходства Dice для сегментации предстательной железы составил 0,71, а площадь под ROC-кривой (AUROC) – 81,16 %.

Заключение. Система DL-CAD демонстрирует перспективы для пациентов с клинически значимым раком предстательной железы за счет повышения диагностической точности. Несмотря на высокую специфичность, необходимы дальнейшие улучшения в чувствительности и точности сегментации. Эти улучшения могут быть достигнуты за счет использования более крупных наборов данных и передовых техник глубокого обучения, таких как трансферное обучение или ансамблевое обучение, которые могут повысить чувствительность без ущерба для специфичности. Требуется дальнейшая многоцентровая валидация для ускорения интеграции данной системы в клиническую практику.

Ключевые слова: рак предстательной железы, мультипараметрическая магнитно-резонансная томография, искусственный интеллект, глубокое обучение, PI-RADS

Для цитирования: Mingze He, Еникеев М.Э., Рзаев Р.Т. и др. Разработка системы на базе глубокого обучения для помощи в принятии врачебных решений в определении оценок по системе PI-RADS: международное многоцентровое исследование. Онкоурология 2024;20(4):15–23.

DOI: <https://doi.org/10.17650/1726-9776-2024-20-4-15-23>

Development of a deep learning-based system for aiding in the determination of Prostate Imaging Reporting and Data System (PI-RADS) scores: an international multicenter study

He Mingze¹, M.E. Enikeev¹, R.T. Rzaev², I.M. Chernenkiy¹, M.V. Feldsherov², Li He³, Hu Kebang⁴, E.V. Shpot¹, L.M. Rapoport¹, P.V. Glybochko¹

¹Institute for Urology and Reproductive Health, I.M. Sechenov First Moscow State Medical University, Ministry of Health of Russia (Sechenov University); Build. 1, 2 Bol'shaya Pirogovskaya St., Moscow 119435, Russia;

²Department of Radiology, The Second University Hospital, I.M. Sechenov First Moscow State Medical University, Ministry of Health of Russia (Sechenov University); Build. 1, 6 Bol'shaya Pirogovskaya St., Moscow 119435, Russia;

³Department of Radiology, The First Hospital of Jilin University; Changchun, China;

⁴Department of Urology, The First Hospital of Jilin University; Changchun, China

Contacts: He Mingze hemingze97@gmail.com

Background. Prostate multiparametric magnetic resonance imaging is widely recommended prior to biopsy in clinical practice, with the Prostate Imaging Reporting and Data System (PI-RADS) as the standard tool for guiding diagnosis and treatment decisions. However, analyzing multiparametric magnetic resonance imaging data demands substantial expertise, and the process is often time-intensive and cognitively challenging, leading to variability between and within readers.

Aim. To create a deep learning-based computer-aided diagnosis (DL-CAD) system to minimize manual influence on PI-RADS score determination.

Materials and methods. Between January 2020 and May 2024, 108 patients with histopathologically confirmed prostate cancer with PI-RADS scores 4–5 were retrospectively selected for model development and training. Additionally, 28 benign cases were included for model validation. Different prostate zones were labeled following PI-RADS v2.1 guidelines to facilitate model selection. Manual segmentation of prostate regions and lesions was performed on T2-weighted (T2W) sequences, and a 3D U-Net architecture was implemented for the DL model using the MONAI framework. Diagnostic performance was assessed using Python-based statistical analysis.

Results. The DL-CAD system achieved average accuracy of 78 %, sensitivity of 60 %, and specificity of 84 % for lesion detection. The Dice similarity coefficient for prostate segmentation was 0.71, and the AUROC was 81.16 %.

Conclusion. The DL-CAD system demonstrates promise for patients with clinically significant prostate cancer by improving diagnostic accuracy. While it exhibits high specificity, further improvements of sensitivity and segmentation accuracy are necessary. These improvements could be achieved through the use of larger datasets and advanced deep learning techniques, such as transfer learning or ensemble learning, which could enhance sensitivity without compromising specificity. Further multicenter validation is required to accelerate the integration of this system into clinical practice.

Keywords: prostate cancer, multiparametric magnetic resonance imaging, artificial intelligence, deep learning, PI-RADS

For citation: Mingze He, Enikeev M.E., Rzaev R.T. et al. Development of a deep learning-based system for aiding in the determination of Prostate Imaging Reporting and Data System (PI-RADS) scores: an international multicenter study. *Onkourologiya = Cancer Urology* 2024;20(4):15–23. (In Russ.).

DOI: <https://doi.org/10.17650/1726-9776-2024-20-4-15-23>

Введение

Рак предстательной железы (РПЖ) остается одной из наиболее распространенных злокачественных опухолей среди мужского населения, при этом отмечается тенденция к увеличению заболеваемости [1]. Мультипараметрическая магнитно-резонансная томография (мпМРТ) широко признана как стандартный метод визуализации при подозрении на РПЖ [2]. Прогресс в области фьюжн-навигационной биопсии, объединяющей МРТ и трансректальное ультразвуковое исследование, показал потенциал в улучшении выявления и локализации поражений, что способствует повышению точности последующих стратегий лечения [3]. Система PI-RADS (Prostate Imaging Reporting and Data System) служит стандартизован-

ным протоколом для интерпретации и составления отчетов по мпМРТ и значительно улучшила неинвазивную оценку РПЖ [4]. В соответствии с рекомендациями Европейской ассоциации урологов, пациентам с оценкой PI-RADS 3 и выше рекомендуется систематическая биопсия с использованием системы оценок PI-RADS и данных мпМРТ [5]. Данное сочетание существенно способствовало решению проблем переоценки и перелечивания [6].

Несмотря на доказанную клиническую значимость мпМРТ в диагностике РПЖ, интерпретация данных мпМРТ требует высокого уровня квалификации; анализ остается сложным, трудоемким и потенциально может снижать чувствительность и специфичность [7, 8]. Кроме этого, вариабельность интерпретаций между разными

рентгенологами, а также у одного и того же рентгенолога указывает на необходимость улучшения категоризации поражений, что способствует несоответствиям в принятии решений о биопсии [9]. В связи с этим предполагается использование компьютерной системы диагностики, управляемой искусственным интеллектом (CAD), которая может способствовать стандартизации оценок PI-RADS на основе данных мпМРТ, ускоряя процесс интерпретации и повышая диагностические результаты [10, 11].

Данное исследование направлено на разработку системы CAD на базе глубокого обучения (DL), представляющей собой модель машинного обучения [12], для предоставления более точной и детализированной информации о характеристиках заболевания. С учетом критической важности выбора оптимального алгоритма DL и дефицита размеченных изображений, необходимых для надежного обучения DL-модели [13], а также существующего препятствия в междисциплинарном сотрудничестве разработка системы DL-CAD, отвечающей нашим целям, представляет собой сложную задачу.

Цель исследования – разработка системы DL-CAD для минимизации ручного влияния на определение оценок PI-RADS и предоставление первоначальных выводов и результатов, закладывающих основу для будущих исследований.

Материалы и методы

Дизайн исследования и популяция пациентов

Исследование проводилось в Институте урологии и репродуктивного здоровья Сеченовского Университета и отделении урологии Первой больницы Цилинского университета. Получено одобрение локального этического комитета (№ 02–23 от 26.01.2023), требование письменного информированного согласия не проводилось. Все процедуры соответствовали этическим стандартам Хельсинкской декларации. Для обучения модели DL выборка пациентов была ретроспективной.

С января 2020 г. по май 2024 г. были отобраны пациенты с оценками по системе PI-RADS 4 и 5, у которых был гистологически подтвержденный диагноз РПЖ. Исходная когорта состояла из 241 пациента, из которых 133 были исключены по различным причинам: предыдущее лечение ($n = 27$), РПЖ с экстракапсулярным распространением или дистантными метастазами ($n = 42$), отсутствие гистологических результатов ($n = 18$), отсутствие измеряемого коэффициента диффузии (ИКД) или последовательностей динамического контрастного усиления (ДКУ) ($n = 37$), плохое качество изображений мпМРТ ($n = 9$). Кроме этого, для оценки работы модели были включены 28 пациентов с PI-RADS 1–2, подтвержденными гистологическими исследованиями. В результате в исследование были включены 136 пациентов (рис. 1).

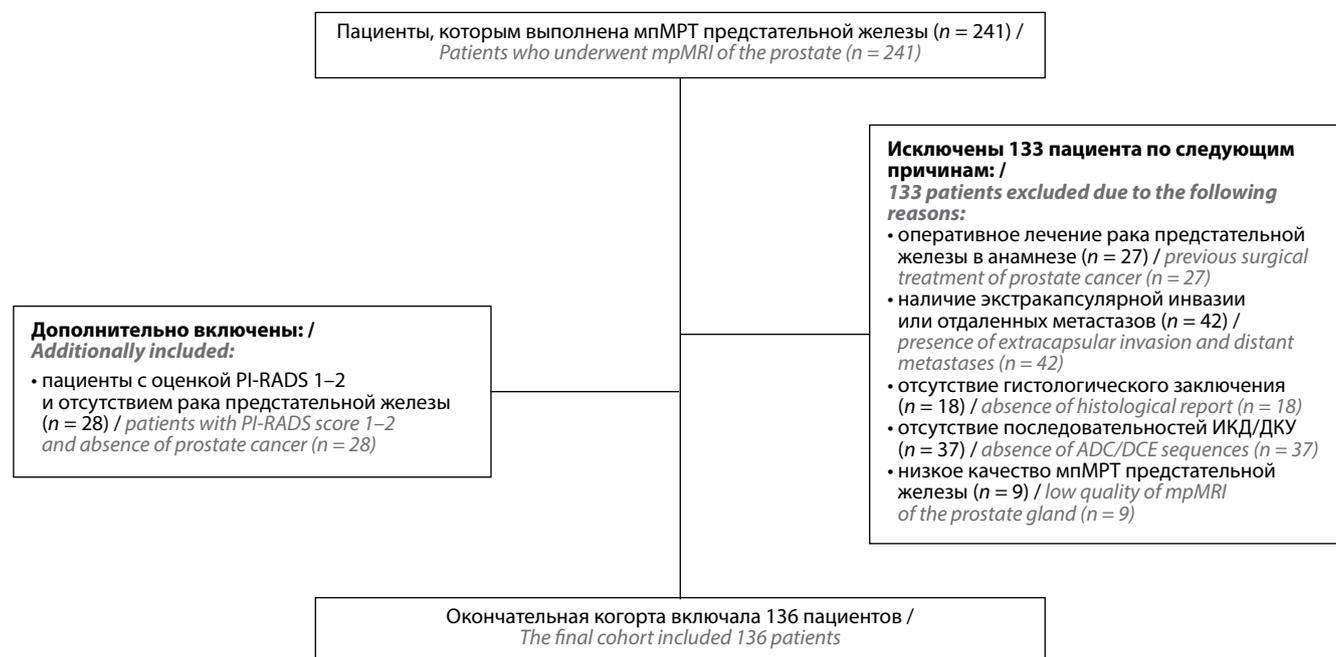


Рис. 1. Схема выбора пациентов. мпМРТ – мультипараметрическая магнитно-резонансная томография; ИКД – измеряемый коэффициент диффузии; ДКУ – динамическое контрастное усиление

Fig. 1. Patient selection scheme. mpMRI – multiparametric magnetic resonance imaging; ADC – apparent diffusion coefficient; DCE – dynamic contrast-enhanced imaging

Обработка изображений магнитно-резонансной томографии

После анонимизации изображения магнитно-резонансной томографии (МРТ) были преобразованы в файлы DICOM и вручную сегментированы урологами и рентгенологами из 2 клинических центров. На предварительном этапе для оптимального выбора модели DL и облегчения нагрузки на алгоритм DL центральная доля была определена как передняя транзиторная зона (TZa), задняя транзиторная зона (TZp) и передняя фибромускулярная строма (AFS) в соответствии с руководствами PI-RADS v2.1. Кроме этого, передняя периферическая зона (PZa), заднелатеральная периферическая зона (PZpl) и заднемедиальная периферическая зона (PZpm) были категоризированы как периферическая доля. Ручная маркировка всей предстательной

железы, а также центральных и периферийных долей была выполнена с использованием T2-взвешенных последовательностей в программном обеспечении Amiga (версия 5.4.5), за которой последовала необходимая техническая обработка (рис. 2).

Протокол параметров магнитно-резонансной томографии

Сканирования мпМРТ предстательной железы проводились с использованием системы МРТ 3.0 T (SIGNA Architect, Чикаго, Иллинойс, США) с применением 30-канальной катушки AIR™. Последовательности МРТ были получены в соответствии с руководствами PI-RADS v2.1, как указано в табл. 1. Протокол визуализации включал T2-взвешенные изображения (T2-ВИ), диффузионно-взвешенные изображения (ДВИ) и последовательности с ДКУ. Для ДВИ использовались значения b 50, 800 и 1400 с/мм², а также синтетические значения b 2000 и 2500 с/мм². Карты ИКД автоматически генерировались для качественного и количественного анализа данных ДВИ. Осевые изображения ДКУ получали до, во время и после быстрой инъекции хелата гадолиния (14 фаз по 16 с на фазу) с использованием инжектора Medrad Spectris Solaris EP (Bayer), за которым следовала промывка 20 мл солевого раствора со скоростью 2,5 мл/с. Все осевые изображения рассматривались в одной и той же анатомической локации для обеспечения согласованности.

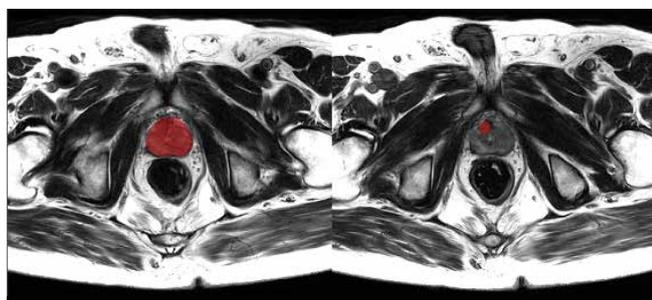


Рис. 2. Сегментация и маркировка предстательной железы и опухоли
 Fig. 2. Segmentation and labeling of the prostate gland and tumor

Таблица 1. Параметры различных последовательностей мультипараметрической магнитно-резонансной томографии

Table 1. Parameters of multiparametric magnetic resonance imaging sequences

Параметр Parameter	T2-ВИ сагиттальный T2-WI sagittal	T2-ВИ аксиальный T2-WI axial	T2-ВИ коронарный T2-WI coronal	ДВИ DWI	ДКУ DCE	T1-ВИ T1-WI
Время повторения, мс Repetition time, ms	3889	3933	2992	6041	5,1	478
Время эхо, мс Echo time, ms	115,9	133,8	115,9	79,8	1–1,1	7,1
Толщина среза, мм Slice thickness, mm	2,5	2,5	2,5	2,5	2,6	4
Промежуток между срезами, мм Intersection gap, mm	0,3	0,3	0,3	0,3	–1,3	0
Угол наклона, градус Flip angle, °	142	120	142	90	12	111
Поле зрения, мм ² Field of view, mm ²	200	200	200	200	300	300
Матрица сбора данных Acquisition matrix	384 × 384	384 × 384	384 × 384	128 × 64	160 × 192	384 × 256
Время сбора данных, с Time of acquisition, s	3:38	3:02	2:48	4:56	3:04	3:35
Количество срезов Slice	26	28	20	28	76	48
Полоса пропускания Bandwidth	41,67	41,67	41,67	250	142,86	111,1

Примечание. T2-ВИ – T2-взвешенное изображение; ДВИ – диффузионно-взвешенное изображение; ДКУ – динамическое контрастное усиление; T1-ВИ – T1-взвешенное изображение.

Note. T2-WI – T2-weighted image; DWI – diffusion-weighted imaging; DCE – dynamic contrast-enhanced imaging; T1-WI – T1-weighted image.

Обработка модели глубокого обучения

Нейронная сеть DL была обучена с использованием фреймворка MONAI, в котором реализована архитектура 3D U-Net с 4 блоками понижающей дискретизации (рис. 3). Набор данных для обучения включал изображения T2-ВИ, ИКД и ДВИ. Эти изображения обрабатывались в патчи размером $192 \times 192 \times 64$ вокселя с пространственным разрешением $0,5 \times 0,5 \times 3,0$ мм.

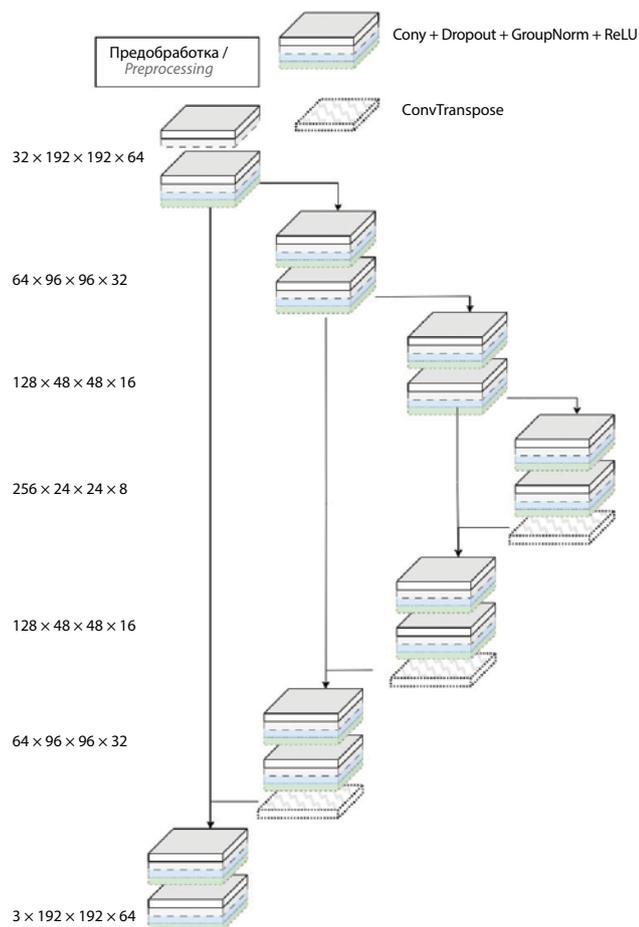


Рис. 3. Схематическое изображение нейронной сети 3D U-Net
Fig. 3. Diagram of the 3D U-Net neural network

Для проверки и обучения модели применялась кросс-валидация данных, которые были разделены на 2 группы: 1-я группа состояла из 108 случаев с оценками PI-RADS 4–5, дополнительно разделенных на 5 групп, включая 22 проверочных случая и 86 тренировочных случаев; 2-я группа состояла из 28 случаев с PI-RADS 1–2,

специально использованных для оценки эффективности модели в обнаружении поражений.

Статистический анализ

Статистический анализ проводили с использованием Python версии 3.11 с применением функционала библиотек Pandas, NumPy и SciPy. Диагностическую эффективность оценивали путем расчета площади под кривой рабочих характеристик приемника (AUROC). Качество сегментации оценивали с применением коэффициента сходства Dice. Чувствительность, специфичность и точность рассчитывали с помощью библиотеки `ricai_eval`.

Результаты

Демография пациентов и клинические характеристики

В этом ретроспективном многоцентровом исследовании когорта пациентов состояла из 136 человек, включая 108 пациентов с РПЖ с оценками PI-RADS 4–5 и 28 мужчин без диагноза РПЖ с PI-RADS 1–2. Всем участникам выполняли либо систематическую биопсию, либо целевую биопсию с фьюжн-навигацией (МРТ-ультразвук). Средний возраст пациентов с оценками PI-RADS 4–5 составил 69,3 (54–84) года (стандартное отклонение 7,16 года), пациентов с оценками PI-RADS 1–2 – 37,9 (18–53) года (стандартное отклонение 10,53 года). Средний уровень простатического специфического антигена в группе PI-RADS 4–5 составлял 39 (1,34–698,53) нг/мл (стандартное отклонение 89,97 нг/мл), в группе PI-RADS 1–2 – 1,29 (0–6,2) нг/мл (стандартное отклонение 1,88 нг/мл). Дополнительная информация о демографических и клинических характеристиках пациентов описана в табл. 2.

Диагностическая эффективность

Система DL-CAD показала среднюю точность $0,78 \pm 0,10$, чувствительность $0,60 \pm 0,09$ и специфичность $0,84 \pm 0,08$ при обнаружении поражений предстательной железы. При сегментации предстательной железы система достигла среднего коэффициента сходства Dice 0,71 в рамках 5-кратной перекрестной проверки. Кроме того, средняя площадь под кривой рабочих характеристик приемника (AUROC) составила 81,16 %, что указывает на хороший баланс между чувствительностью и специфичностью. Подробные диагностические показатели системы DL-CAD представлены на рис. 4.

Таблица 2. Демографические и клинические характеристики пациентов

Table 2. Patient demographics and clinical characteristics

Характеристика Characteristic	PI-RADS 4–5	PI-RADS 1–2
Число пациентов Number of patients	108	28
Средний возраст (диапазон), лет Mean age (range), years	69,3 (54–84)	37,9 (18–53)
Средний уровень простатического специфического антигена (диапазон), нг/мл Prostate-specific antigen, mean (range), ng/mL	39,00 (1,34–698,53)	1,29 (0–14)
Сумма баллов по шкале Глисона, n: Gleason score, n:		
6	21	
7a	26	
7b	24	–
8	17	
9	14	
10	6	

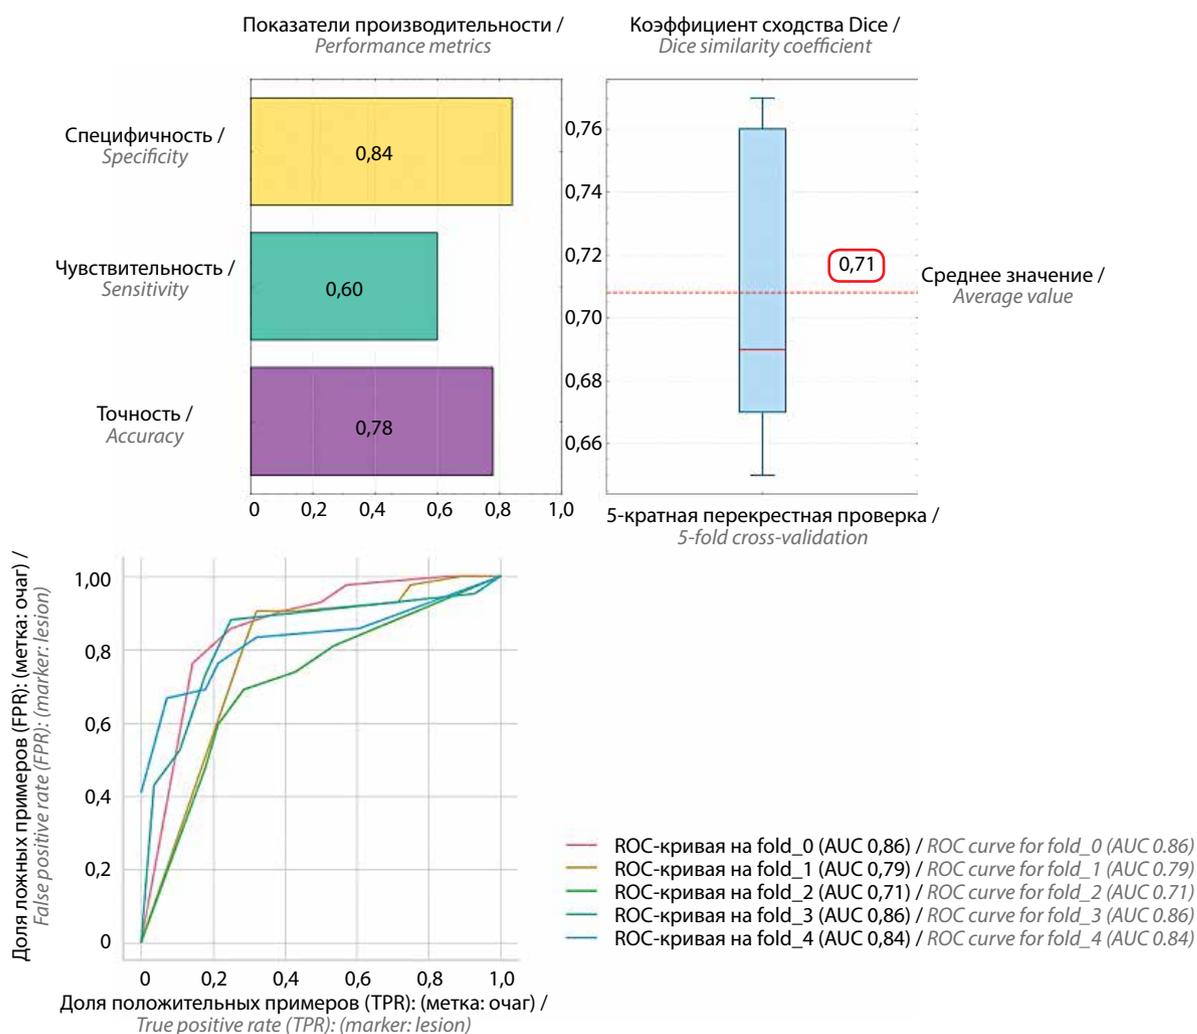


Рис. 4. Диагностические показатели разработанной системы DL-CAD. AUC – площадь под ROC-кривой
 Fig. 4. Diagnostic performance of the developed DL-CAD system. AUC – area under the ROC curve

Обсуждение

По нашим данным, настоящее исследование является одним из первых в России, посвященных системе DL-CAD для обнаружения РПЖ с использованием PI-RADS v2.1. Основная цель этого исследования заключалась в помощи клиницистам в оценке клинико-радиологических аспектов РПЖ, что, в свою очередь, поддерживает последующие диагностические и лечебные решения. Ручная интерпретация данных мпМРТ представляет значительные трудности, особенно из-за изменчивости оценок PI-RADS между разными рентгенологами и у одного и того же рентгенолога, что является хорошо задокументированной проблемой при диагностике РПЖ [14]. Такая изменчивость мешает последовательному применению мпМРТ в клинических условиях, снижает диагностическую точность и увеличивает риск как пере-, так и недодиагностики [15]. Эта неправильная диагностика не только влияет на исходы для пациентов, но и может приводить к увеличению смертности, связанной с задержкой или неправильным лечением. Следовательно, разработка системы DL-CAD для помощи в оценке по системе PI-RADS критически важна, так как она предлагает возможность повышения диагностической точности, упрощения интерпретации и снижения влияния субъективных человеческих факторов.

Наши результаты показывают, что система DL-CAD достигла средней диагностической точности 78 % со специфичностью 84 %, чувствительностью 60 % при обнаружении поражений и коэффициентом сходства Dice 0,71 при сегментации предстательной железы. Эти результаты подчеркивают потенциал технологии DL для улучшения диагностической согласованности и снижения изменчивости оценок между разными рентгенологами при интерпретации данных мпМРТ, что является давней проблемой при диагностике РПЖ.

X. Min и соавт. использовали алгоритмы MRMR и LASSO для разделения клинически значимого и не клинически значимого РПЖ, сообщив о площади под кривой (AUC) 82,3 % с чувствительностью и специфичностью 84,1 и 72,7 % соответственно [16]. В исследовании Y. Liu и соавт. применяли текстурный подход DL в сочетании со сверточной нейронной сетью (CNN), включая последовательности T2-ВИ и ИКД, для оценки способностей обнаружения рака. С большим объемом выборки ($n = 402$) этот подход достиг AUC 85 % и специфичности 70 %. Это исследование указывает на предпочтение специфичности, эффективно снижающей ложноположительные результаты [17].

В 2020 г. N. Aldo и соавт. модифицировали структуру своей нейронной сети, применяя 3D CNN для разделения клинически значимого и не клинически значимого РПЖ с использованием нескольких последовательностей МРТ, включая изображения ИКД, ДВИ и ДКУ. Несмотря на меньший объем выборки ($n = 175$),

их модель достигла AUC 89,7 %, чувствительности 81,9 % и специфичности 86,1 %, что отражает надежную производительность, при которой как чувствительность, так и специфичность превышают показатели, наблюдаемые в нашем исследовании [18]. Тем не менее коэффициент сходства Dice для сегментации предстательной железы в нашей модели DL (0,71) указывает на высокую точность сегментации, что является ключевым фактором для точной локализации поражений предстательной железы.

По сравнению с текущими предложенными моделями DL специфичность 84 %, наблюдаемая в нашем исследовании, особенно значима, указывая на сниженный уровень ложноположительных результатов, что важно для минимизации ненужных биопсий и вмешательств. Используя оценки PI-RADS v2.1 и передовые методы DL, наша модель демонстрирует потенциал для повышения диагностической точности и снижения вариабельности в интерпретациях данных мпМРТ. Применение архитектуры 3D U-Net показало свою эффективность для точной сегментации предстательной железы. Достигнутая AUROC 81,16 % дополнительно свидетельствует о том, что система DL-CAD обладает потенциалом для поддержки принятия клинических решений, сочетая высокую диагностическую производительность с сокращением риска ненужных процедур.

Несмотря на перспективные результаты, данное исследование сталкивается с несколькими ограничениями, которые заслуживают внимания. Во-первых, относительно малый размер выборки для обучения и валидации модели может ограничить обобщаемость результатов. Несмотря на то что коэффициент сходства Dice 0,71 указывает на надежную точность сегментации, существует потенциал для дальнейшего совершенствования. Изначально мы обогатили обучение нашей модели 1500 случаями из набора данных PICA1 [19], ожидая улучшения производительности модели за счет воздействия на более крупный и разнообразный набор данных, особенно с точки зрения чувствительности. Однако этот подход привел к субоптимальным результатам по сравнению с моделью, обученной без предварительного обучения. Это может быть частично объяснено возможными несоответствиями в протоколах визуализации в разных центрах, приводящими к расхождению распределений пикселей МРТ, что может мешать процессу обучения модели DL. Стандартизация протоколов визуализации или их лучшее согласование между центрами потенциально может решить эту проблему.

Еще одним заметным ограничением является относительно низкая чувствительность (60 %), подчеркивающая критическую область для улучшения. Увеличение чувствительности имеет решающее значение для точного определения истинно положительных случаев, особенно при обнаружении клинически значимого

РПЖ. Повышение чувствительности при сохранении специфичности будет ключевым направлением для будущего усовершенствования модели. Передовые методы обучения, такие как трансферное обучение или многоцелевое обучение, изученные в исследованиях R. Сао и соавт. [20] и D. Ноаг и соавт. [21], могут быть ценными для достижения этих улучшений. Дальнейшее расширение модели для включения дополнительных последовательностей МРТ, таких как T1-взвешенная визуализация или интеграция клинических параметров, также может улучшить ее диагностические возможности для обнаружения поражений. Эти стратегии предоставляют потенциальные пути для разработки более надежной модели с улучшенной диагностической производительностью в различных клинических условиях, поддерживая ее полезность для более эффективного определения клинически значимого РПЖ.

Заключение

Разработанная система DL-CAD показывает значительный потенциал в поддержке определения оце-

нок PI-RADS, что способствует улучшению клинического принятия решений у пациентов с клинически значимым РПЖ и снижает меж- и внутриэкспертную вариабельность. Высокая специфичность системы 84 % и умеренная чувствительность 60 % выделяют ее способность минимизировать ложноположительные результаты и уменьшать количество ненужных биопсий, что является ключевым для улучшения результатов лечения пациентов. Тем не менее необходимо повышение чувствительности для более точного выявления поражений, что остается критической задачей для дальнейшей разработки. Достижение этой цели возможно за счет использования более крупных и разнообразных наборов данных, интеграции дополнительных последовательностей МРТ, включения клинических параметров и применения передовых методов адаптации нейронных сетей DL. Кроме этого, проведение многоцентровых исследований и сбор дополнительных изображений станут ключевыми для оптимизации диагностической эффективности модели и ускорения ее внедрения в клиническую практику.

ЛИТЕРАТУРА / REFERENCES

1. Bray F, Ferlay J., Soerjomataram I. et al. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA Cancer J Clin* 2018;68(6):394–424. DOI: 10.3322/caac.21492
2. Bagheri H., Mahdavi S.R., Geramifard P. et al. An update on the role of mpMRI and (68)Ga-PSMA PET imaging in primary and recurrent prostate cancer. *Clin Genitourin Cancer* 2024;22(3):102076. DOI: 10.1016/j.clgc.2024.102076
3. Kaneko M., Sugano D., Lebastchi A.H. et al. Techniques and outcomes of MRI-TRUS fusion prostate biopsy. *Curr Urol Rep* 2021;22(4):27. DOI: 10.1007/s11934-021-01037-x
4. Weinreb J.C., Barentsz J.O., Choyke P.L. et al. PI-RADS prostate imaging – reporting and data system: 2015, Version 2. *Eur Urol* 2016;69(1):16–40. DOI: 10.1016/j.eururo.2015.08.052
5. Ahdoot M., Lebastchi A.H., Long L. et al. Using Prostate Imaging-Reporting and Data System (PI-RADS) scores to select an optimal prostate biopsy method: a secondary analysis of the Trio study. *Eur Urol Oncol* 2022;5(2):176–86. DOI: 10.1016/j.euo.2021.03.004
6. Padhani A.R., Barentsz J., Villeirs G. et al. PI-RADS Steering Committee: the PI-RADS multiparametric MRI and MRI-directed biopsy pathway. *Radiology* 2019;292(2):464–74. DOI: 10.1148/radiol.2019182946
7. Wen J., Liu W., Shen X., Hu W. PI-RADS v2.1 and PSA for the prediction of clinically significant prostate cancer among patients with PSA levels of 4–10 ng/ml. *Sci Rep* 2024;14(1):6570. DOI: 10.1038/s41598-024-57337-y
8. He M., Cao Y., Chi C. et al. Research progress on deep learning in magnetic resonance imaging-based diagnosis and treatment of prostate cancer: a review on the current status and perspectives. *Front Oncol* 2023;13:1189370. DOI: 10.3389/fonc.2023.1189370
9. Smani S., Jalfon M., Sundaresan V. et al. Inter-reader reliability and diagnostic accuracy of PI-RADS scoring between academic and community care networks: how wide is the gap? *Urol Oncol* 2024;S1078-1439(24)00681-1. DOI: 10.1016/j.urolonc.2024.10.002
10. Savadjiev P., Chong J., Dohan A. et al. Demystification of AI-driven medical image interpretation: past, present and future. *Eur Radiol* 2019;29(3):1616–24. DOI: 10.1007/s00330-018-5674-x
11. Rouvière O., Jaouen T., Baseilhac P. et al. Artificial intelligence algorithms aimed at characterizing or detecting prostate cancer on MRI: How accurate are they when tested on independent cohorts? A systematic review. *Diagn Interv Imaging* 2023;104(5):221–34. DOI: 10.1016/j.diii.2022.11.005
12. Taye M.M. Understanding of machine learning with deep learning: architectures, workflow, applications and future directions. *Computers* 2023;12(5):91.
13. Alzubaidi L., Bai J., Al-Sabaawi A. et al. A survey on deep learning tools dealing with data scarcity: definitions, challenges, solutions, tips, and applications. *J Big Data* 2023;10(1):46. DOI: 10.1186/s40537-023-00727-2
14. Singh D., Kumar V., Das C.J. et al. Machine learning-based analysis of a semi-automated PI-RADS v2.1 scoring for prostate cancer. *Front Oncol* 2022;12:961985. DOI: 10.3389/fonc.2022.961985
15. Annamalai A., Fustok J.N., Beltran-Perez J. et al. Interobserver agreement and accuracy in interpreting mpMRI of the prostate: a systematic review. *Curr Urol Rep* 2022;23(1):1–10. DOI: 10.1007/s11934-022-01084-y
16. Min X., Li M., Dong D. et al. Multi-parametric MRI-based radiomics signature for discriminating between clinically significant and insignificant prostate cancer: cross-validation of a machine learning method. *Eur J Radiol* 2019;115:16–21. DOI: 10.1016/j.ejrad.2019.03.010
17. Liu Y., Zheng H., Liang Z. et al. Textured-based deep learning in prostate cancer classification with 3T multiparametric MRI: comparison with PI-RADS-based classification. *Diagnostics (Basel)* 2021;11(10):1785. DOI: 10.3390/diagnostics11101785
18. Aldoj N., Lukas S., Dewey M., Penzkofer T. Semi-automatic classification of prostate cancer on multi-parametric MR imaging

- using a multi-channel 3D convolutional neural network. *Eur Radiol* 2020;30(2):1243–53. DOI: 10.1007/s00330-019-06417-z
19. Saha A., Bosma J.S., Twilt J.J. et al. Artificial intelligence and radiologists in prostate cancer detection on MRI (PI-CAI): an international, paired, non-inferiority, confirmatory study. *Lancet Oncol* 2024;25(7):879–87. DOI: 10.1016/s1470-2045(24)00220-1
20. Cao R., Mohammadian Bajgiran A., Afshari Mirak S. et al. Joint prostate cancer detection and Gleason score prediction in mp-MRI via FocalNet. *IEEE Trans Med Imaging* 2019;38(11):2496–506. DOI: 10.1109/tmi.2019.2901928
21. Hoar D., Lee P.Q., Guida A. et al. Combined transfer learning and test-time augmentation improves convolutional neural network-based semantic segmentation of prostate cancer from multi-parametric MR images. *Comput Methods Programs Biomed* 2021;210:106375. DOI: 10.1016/j.cmpb.2021.106375

Вклад авторов

He Mingze: сбор материала, анализ данных, написание текста статьи;
М.Э. Еникеев, Е.В. Шпот: разработка дизайна исследования, редактирование текста статьи;
Р.Т. Рзаев: анализ данных, получение данных для анализа, редактирование текста статьи;
И.М. Черненкокий, Li He: анализ данных;
М.В. Фельдшеров, Л.М. Рапопорт, П.В. Глыбочко: разработка дизайна исследования;
Hu Kebang: получение данных для анализа, анализ данных.

Authors' contributions

He Mingze: data acquisition, data analysis, article writing;
M.E. Enikeev, E.V. Shpot: study design, article editing;
R.T. Rzaev: data analysis, obtaining data for analysis, article editing;
I.M. Chernenkiy, Li He: data analysis;
M.V. Feldsherov, L.M. Rapoport, P.V. Glybochko: study design;
Hu Kebang: data acquisition, data analysis.

ORCID авторов / ORCID of authors

He Mingze: <https://orcid.org/0000-0003-0601-4713>
М.Э. Еникеев / M.E. Enikeev: <https://orcid.org/0000-0002-3007-1315>
Р.Т. Рзаев / R.T. Rzaev: <https://orcid.org/0000-0002-6005-6247>
И.М. Черненкокий / I.M. Chernenkiy: <https://orcid.org/0000-0001-5968-9883>
М.В. Фельдшеров / M.V. Feldsherov: <https://orcid.org/0000-0001-6808-7498>
Hu Kebang: <https://orcid.org/0000-0003-2860-276X>
Е.В. Шпот / E.V. Shpot: <https://orcid.org/0000-0003-1121-9430>
Л.М. Рапопорт / L.M. Rapoport: <https://orcid.org/0000-0001-7787-1240>
П.В. Глыбочко / P.V. Glybochko: <https://orcid.org/0000-0002-5541-2251>

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.
Conflict of interest. The authors declare no conflict of interest.

Финансирование. Исследование проведено без спонсорской поддержки.
Funding. The study was performed without external funding.

Соблюдение прав пациентов и правил биоэтики

Исследование проведено в соответствии с Хельсинкской декларацией и одобрено локальным этическим комитетом ФГАОУ ВО Первый Московский государственный медицинский университет им. И.М. Сеченова Минздрава России (Сеченовский Университет) (№ 02-23 от 26.01.2023).

Compliance with patient rights and principles of bioethics

The study was performed in accordance with the Declaration of Helsinki and was approved by the Ethics Committee of I.M. Sechenov First Moscow State Medical University, Ministry of Health of Russia (Sechenov University) (No. 02-23 from 26.01.2023).

Заявление о доступности данных. Данные, представленные в этом исследовании, доступны по запросу у соответствующего автора.
Data availability statement. Data presented in this study are available on request from the corresponding author.

Статья поступила: 30.10.2024. Принята к публикации: 23.01.2025. Опубликована онлайн: 24.02.2025.
Article submitted: 30.10.2024. Accepted for publication: 23.01.2025. Published online: 24.02.2025.