

Алгоритмизация консенсусной разметки очаговых изменений предстательной железы для проведения текстурного анализа

М.О. Романенко¹, М.Р. Коденко^{1,2}, П.Б. Гележе^{1,3}, И.А. Блохин¹, Р.В. Решетников¹

¹ Научно-практический клинический центр диагностики и телемедицинских технологий, Москва, Россия;

² Московский государственный технический университет имени Н.Э. Баумана (национальный исследовательский университет), Москва, Россия;

³ Европейский медицинский центр, Москва, Россия

АННОТАЦИЯ

Обоснование. Текстурный анализ позволяет повысить диагностическую точность магнитно-резонансной томографии и улучшить дифференциальную диагностику очаговых изменений предстательной железы. Основным методом их сегментации для проведения текстурного анализа является ручная разметка, для которой характерна значительная вариабельность масок между разметчиками. Для уменьшения расхождений при сегментации патологических очагов предстательной железы можно использовать метод консенсуса. Однако в мировой литературе не представлено стандартизированных протоколов консенсусной разметки.

Цель исследования. Разработать алгоритм формирования консенсуса при независимой ручной разметке патологических очагов предстательной железы несколькими экспертами, оценить согласованность экспертов при сегментации её очаговых изменений.

Методы. В ретроспективное исследование включено 60 результатов бипараметрической магнитно-резонансной томографии предстательной железы, выполненной в соответствии с технической спецификацией PI-RADS 2.1, с гистологически верифицированными патологическими очагами, соответствующими категориям PI-RADS 3, 4 и 5. Два эксперта-рентгенолога независимо друг от друга сегментировали очаги предстательной железы ручным методом в программном обеспечении 3D Slicer. Полученные маски сопоставляли между собой с подсчётом коэффициента сходства Сёрнсена–Дайса. Для очагов с коэффициентом, равным 0,75 и выше, в качестве итоговой принимали пересечение двух исходных масок. Для очагов с коэффициентом сходства Сёрнсена–Дайса ниже порогового значения итоговую маску определяли с использованием разработанного алгоритма консенсуса.

Результаты. Разработанный алгоритм достижения консенсуса позволил статистически значимо увеличить значение коэффициента сходства Сёрнсена–Дайса с 0,61 [0,48; 0,73] при первичной разметке до 0,74 [0,62; 0,79] при использовании предложенного алгоритма ($p=0,01$).

Заключение. Разработанный алгоритм консенсусной разметки очаговых изменений предстательной железы по данным магнитно-резонансной томографии является важным вкладом в решение проблемы недостаточной проработанности подходов к объективной сегментации в научной и клинической практике.

Ключевые слова: магнитно-резонансная томография; очаговые изменения предстательной железы; сегментация; консенсус; PI-RADS; радиомика.

КАК ЦИТИРОВАТЬ:

Романенко М.О., Коденко М.Р., Гележе П.Б., Блохин И.А., Решетников Р.В. Алгоритмизация консенсусной разметки очаговых изменений предстательной железы для проведения текстурного анализа // Digital Diagnostics. 2025. Т. 6, № 3. С. XX–XX. DOI: 10.17816/DD637445 EDN: NYKFGN

Рукопись получена: 24.10.2024

Рукопись одобрена: 25.12.2024

Опубликована online: 25.08.2025

Статья доступна по лицензии CC BY-NC-ND 4.0 International

© Эко-Вектор, 2025

Consensus-based decision tree for prostatic lesion segmentation in radiomics

Maria O. Romanenko¹, Maria R. Kodenko^{1,2}, Pavel B. Gelezhe^{1,3}, Ivan A. Blokhin¹, Roman V. Reshetnikov¹

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies, Moscow, Russia;

² Bauman Moscow State Technical University, Moscow, Russia;

³ European Medical Center, Moscow, Russia

ABSTRACT

BACKGROUND: Texture analysis can increase the diagnostic accuracy of magnetic resonance imaging (MRI) and improve the differential diagnosis of prostatic lesions. Manual segmentation is commonly used for lesion delineation and subsequent texture analysis. However, this approach is confounded by high inter-observer variability. Consensus-based methods can be used to reduce variability in prostatic contour delineation. To date, no worldwide standardized consensus-based segmentation algorithms have been proposed.

AIM: To create a consensus-based algorithm for manual prostatic lesion segmentation; to assess the agreement among experts when using the algorithm.

METHODS: 60 biparametric MRI scans performed per PI-RADS 2.1 and containing PI-RADS 3, 4, and 5 lesions were included in this retrospective study. Two radiologists independently and manually delineated all prostatic lesions using 3D Slicer software. The obtained masks were compared by calculating the Dice similarity coefficient. For prostatic lesions with DSC of 0.75 or greater, the overlap between two masks was selected as the final mask. For prostatic lesions with DSC below than 0.75, final masks were generated using the developed consensus-based algorithm.▶

RESULTS: The proposed consensus algorithm statistically significantly increased the median DSC value from 0.61 (0.48; 0.73) ($p=0.01$) to 0.74 (0.62; 0.79) after algorithm application.

CONCLUSION: The developed decision tree for prostatic lesion segmentation augments existing scientific and methodological literature, by objectifying the segmentation process and increasing the DSC value.

Keywords: magnetic resonance imaging; prostate lesion; segmentation; consensus; PI-RADS; radiomics.

TO CITE THIS ARTICLE:

Romanenko MO, Kodenko MR, Gelezhe PB, Blokhin IA, Reshetnikov RV. Consensus-based decision tree for prostatic lesion segmentation in radiomics. *Digital Diagnostics*. 2025;6(3):XX–XX. DOI: 10.17816/DD637445 EDN: NYKFGN

Submitted: 24.10.2024

Accepted: 25.12.2024

Published online: 25.08.2025

The article can be used under the CC BY-NC-ND 4.0 International License

© Eco-Vector, 2025

ОБОСНОВАНИЕ

Радиомический анализ является перспективным методом дифференциальной диагностики новообразований предстательной железы, учитывая, что диагностическая точность магнитно-резонансной томографии в клинической практике может варьировать в зависимости от протокола сканирования и опыта рентгенолога, интерпретирующего исследование [1, 2]. Применение радиомического анализа потенциально позволит избежать неоправданной биопсии и сопряжённых с ней осложнений [3], что особенно важно в случаях неопределённых очагов предстательной железы [4]. Тем не менее внедрение радиомики в рутинную клиническую практику связано с некоторыми трудностями, среди которых одним из ключевых является отсутствие стандартизированного и оптимального инструмента разметки [5, 6].

Наиболее доступным и часто применяемым методом сегментации очагов предстательной железы для последующего текстурного анализа на данный момент является ручной [7].

Одним из главных его недостатков является высокая межэкспертная вариабельность масок, которая приводит к нестабильности извлечённых текстурных показателей [8]. Для количественного определения степени подобия масок используют коэффициент сходства Сёренсена–Дайса (Dice-Sørensen Similarity Coefficient, DSC), значение которого может варьировать от 0 до 1, где 1 — полное их пересечение. По данным М.У. Chen и соавт. [9], при разметке патологических очагов предстательной железы на двух изображениях магнитно-резонансной томографии (МРТ) четырьмя врачами-рентгенологами медиана DSC составила 0,81 и 0,58 для периферической и переходной зон соответственно. Это показывает высокую вариабельность результатов сегментации даже среди опытных специалистов. В исследовании T. Jeganathan и соавт. [10] отмечали ещё большую вариабельность результатов — при сегментации очагов предстательной железы тремя рентгенологами по результатам 64 исследований среднее значение DSC составило 0,55. Его невысокие значения потенциально могут быть обоснованы низкой контрастностью или малыми размерами включённых в исследования патологических очагов. Однако, согласно данным публикаций, даже для очагов с очень высокой вероятностью клинически значимого рака (Prostate Imaging-Reporting and Data System 5, PI-RADS 5), обладающих более чёткими контурами и большими размерами, значительного повышения DSC отмечено не было [10, 11].

Для стандартизации этапов сегментации патологических образований Европейское радиологическое сообщество (European Society of Radiology, ESR) и Европейская организация по исследованию и лечению рака (European Organisation for Research and Treatment of Cancer, EORTC) разработали рекомендации [12], согласно которым при ручной сегментации биомедицинских изображений необходима их итеративная независимая оценка несколькими разметчиками до момента предполагаемого достижения консенсуса и получения итоговой маски. При этом кратность итераций и необходимое количество операторов в рекомендациях не указаны.

Недостаточная детализация процесса достижения консенсуса отражена также в оригинальных исследованиях [13–15]. Согласно литературному анализу, в доступных на момент написания статьи публикациях методология получения итоговой маски описана недостаточно подробно, что затрудняет воспроизведение представленных результатов.

Таким образом, несмотря на активно растущий объём исследований в области радиомики предстательной железы [7], в мировой литературе всё ещё не представлено чётких алгоритмов достижения консенсуса при сегментации её патологических изменений несколькими разметчиками. В связи с этим возникает необходимость в разработке и оценке эффективности подхода к формированию итоговой маски, основанного на согласовании разметок нескольких специалистов. Для этого выдвинуты две гипотезы (табл. 1).

ЦЕЛЬ

Разработать алгоритм формирования консенсуса при независимой ручной разметке патологических очагов предстательной железы несколькими экспертами, оценить согласованность экспертов при сегментации её очаговых изменений.

МЕТОДЫ

ДИЗАЙН ИССЛЕДОВАНИЯ

Проведено наблюдательное одноцентровое ретроспективное исследование (рис. 1).

КРИТЕРИИ СООТВЕТСТВИЯ

Критерии включения: изображения бпМРТ предстательной железы, полученные при выполнении исследования по технической спецификации PI-RADS 2.1, с патологическими очагами, соответствующими категориям PI-RADS: 3 — подозрение на клинически значимый рак предстательной железы; 4 — вероятно его наличие; 5 — высокая его вероятность.

Критерии невключения: очаговые изменения предстательной железы, соответствующие категориям PI-RADS 1 (очень низкая вероятность клинически значимого рака предстательной железы) и PI-RADS 2 (низкая его вероятность), согласно технической спецификации PI-RADS 2.1, а также исследования, выполненные с отклонением от указанного стандарта.

Критерии исключения: исследования низкого качества (с наличием выраженных артефактов, затрудняющих интерпретацию).

СБОР ДАННЫХ

Работа была выполнена с применением зарегистрированного набора данных с гистологической верификацией¹, содержащего 103 анонимизированные записи бпМРТ, полученные при выполнении исследований на томографе MAGNETOM® Aera 1,5 Тл 4G (Siemens Healthcare, Германия) по стандарту PI-RADS 2.1. Для настоящего исследования были выбраны только бпМРТ, поскольку, согласно критериям METRICS (система балльной оценки качества исследований по радиомике) [16], для радиомического анализа целесообразно использовать меньшее количество импульсных последовательностей, чтобы минимизировать риск переобучения модели. После анализа всех изображений из набора данных исключены 43 исследования бпМРТ, содержащие очаговые изменения, отнесенные к категориям PI-RADS 1 и 2, что соответствует очень низкой и низкой вероятности клинически значимого рака предстательной железы. В результате сформирован набор данных, включающий 60 исследований с 69 патологическими очагами, соответствующими критериям PI-RADS 3 и выше.

ЭКСПЕРТЫ

В разметке набора данных принимали участие два врача-рентгенолога (эксперта) с опытом работы в области лучевой диагностики 9 и 12 лет, ранее выполнявшие сегментацию медицинских изображений.

СЕГМЕНТАЦИЯ

При создании набора данных¹ один из экспертов подготовил референсные изображения, на которых схематически отметил интересующие патологические очаги на одном срезе, руководствуясь категорией PI-RADS и результатами мультифокальной фьюжн-биопсии (рис. 2). Таким образом, до начала настоящего исследования прошёл интервал более 6 месяцев после предыдущей работы эксперта с данными, что, согласно кривой забывания Эббингауза, является достаточным для минимизации прежнего опыта на текущую разметку [17].

В настоящем исследовании разметку проводили согласно этим изображениям на всех срезах, содержащих, по мнению разметчика, патологический очаг. Мы посчитали данный шаг оправданным как для удобства разметчиков, так и для уменьшения числа расхождений во время обработки результатов.

Разметку изображений бпМРТ осуществляли с помощью открытого бесплатного программного обеспечения 3D Slicer² (версия 5.6.2) в расширении mpReview (Multiparametric Review), предназначенного для анализа и сегментации мультипараметрических исследований. Эксперты-рентгенологи независимо друг от друга создавали маску отдельно для каждого очага предстательной железы ручным методом с использованием инструмента «контурная кисть» (Draw). В качестве референсной импульсной последовательности выбрали T2-ВИ, поскольку для сопоставления масок сегментируемые изображения должны иметь одинаковое пространственное разрешение. Разметку выполняли послойно с оценкой всего объёма очага. Созданные маски сохраняли в формате NifTI [Neuroimaging Informatics Technology Initiative (.nii)].

¹ Свидетельство о государственной регистрации базы данных № 2024620575/ 06.02.2024. Бюл. № 2. Васильев Ю.А., Блохин И.А., Гележе П.Б., и др. Набор данных бипараметрической МРТ предстательной железы с гистологической верификацией. Режим доступа: https://www.elibrary.ru/download/elibrary_60779494_94785287.PDF Дата обращения: 21.10.2024.

² 3D Slicer image computing platform. В: 3D Slicer [Internet]. 2005–2024. Режим доступа: <https://slicer.org/> Дата обращения: 21.09.24.

ЭТИЧЕСКАЯ ЭКСПЕРТИЗА

Проведение исследования одобрено независимым этическим комитетом при ГБУЗ «НПКЦ ДиТ ДЗМ» (протокол заседания №06/2025 от 19.06.2025).

СТАТИСТИЧЕСКИЙ АНАЛИЗ

Обоснование размера выборки. При наихудшем сценарии, предполагающем максимальное расхождение между разметками (DSC — 1), выборка, включающая 8 патологических очагов, обеспечивает статическую мощность 80% при вероятности ошибки I рода 0,05 [18].

Методы статистического анализа данных. Полученные от экспертов маски поочередно сопоставляли с подсчётом DSC. Результаты представлены в виде $Me [Q1; Q3]$, где Me — медиана, $Q1$ и $Q3$ — 1- и 3-й квартиль соответственно. Определение нормальности распределения данных проводили с использованием теста Шапиро–Уилка. Для установления взаимосвязи между типом очага по PI-RADS и значением DSC применяли коэффициент ранговой корреляции Спирмена (ρ). Уровень статистической значимости при проверке гипотез принят равным 0,05. Расчёты выполняли в программном обеспечении RStudio® версия 4.1.2 (Posit, PBC, Соединённые Штаты Америки) [19].

СОЗДАНИЕ АЛГОРИТМА КОНСЕНСУСНОЙ РАЗМЕТКИ

Поскольку в мировой литературе не представлено общепринятых граничных значений DSC при консенсусной разметке [12], мы решили установить пограничное значение, равное 0,75. В случае, если $DSC \geq 0,75$, то площадь пересечения двух масок сохраняли как итоговую. Если $DSC < 0,75$, то такие очаги предстательной железы подлежали повторному пересмотру совместно двумя экспертами с целью достижения консенсуса.

Мы разработали алгоритм действий, подробно регламентирующий процесс формирования консенсуса по очагам, для которых значение DSC было меньше порогового (рис. 3). Маски, соответствующие данным очагам, анонимизированы и расположены в случайном порядке. Спустя 1 месяц эксперты повторно их просматривали (как свою, так и второго разметчика) в 3D Slicer², не обсуждая их друг с другом. Далее каждый эксперт давал независимую оценку всем маскам патологических очагов, выставляя либо 1 балл («маска соответствует»), либо 0 баллов («маска не соответствует»). Критерий «маска соответствует» в данном случае подразумевает, что, по мнению эксперта, её контуры в достаточной степени совпадают с границами очага. В случае единогласного выбора маски двумя экспертами (суммарная оценка — 2 балла), её использовали в дальнейшем анализе. Если сумма баллов была равна 0 или 1, то маску исключали.

После прохождения обеими масками конкретного патологического очага этапа экспертного голосования возможны следующие сценарии формирования консенсуса:

- при выборе двух масок итоговой считали их область пересечения (расчёт DSC представлен на рис. 4, a);
- при выборе только одной маски именно её использовали в качестве итоговой;
- в случае отклонения обеих масок итоговую формировали совместно два эксперта.

Во втором сценарии после прохождения алгоритма рассчитывали повторно значение DSC, представляющее отношение объёма пересечения двух масок к объёму выбранной (итоговой) маски (см. рис. 4, b). В третьем варианте значение DSC рассчитывали как отношение объёма новой маски к суммарному объёму двух предыдущих масок (см. рис. 4, c, d).

РЕЗУЛЬТАТЫ

Всего проанализировано 60 результатов бпМРТ, полученных при выполнении исследования по стандарту PI-RADS 2.1 и содержащих 69 патологических очагов предстательной железы, соответствующих критериям PI-RADS 3, 4 и 5. Распределение очагов по категориям PI-RADS выглядело следующим образом:

- PI-RADS 3 — 27 очагов (39%);
- PI-RADS 4 — 22 очага (32%);
- PI-RADS 5 — 20 очагов (29%).

После разметки набора данных для каждой пары масок рассчитано исходное (базовое) значение DSC. Распределение его исходных значений продемонстрировано на рис. 5. Для всей выборки значение DSC составило 0,61 [0,48; 0,73].

Количество очагов, для которых $DSC \geq 0,75$, составило 14 (20,2%). Маски остальных очагов ($n=55$, 79,8%) подлежали повторному пересмотру в соответствии с алгоритмом. Ранжирование по категории паологических очагов в группе пересмотра:

- с PI-RADS 3 — 38% (21 случай);
- с PI-RADS 4 — 36% (20 случаев);
- с PI-RADS 5 — 25% (14 случаев).

Для группы пересмотра консенсус (см. рис. 3) достигнут следующим образом:

- для 43 очагов в качестве итоговой маски единогласно выбрана одна из двух предложенных;
- для 11 очагов создана новая итоговая маска, поскольку ни одна из исходных не получила единогласного одобрения;
- для одного очага ($DSC = 0,56$) итоговая маска получена посредством пересечения двух исходных масок, каждая из которых единогласно одобрена обоими экспертами.

Повторный расчёт значений DSC для всей выборки после пересмотра 55 случаев продемонстрировал их изменения. В 27% случаев ($n=15$) определяли уменьшение значений DSC после применения алгоритма. Для всей выборки значение DSC составило 0,74 [0,62; 0,79].

Распределение значений DSC в зависимости от категории PI-RADS патологического очага статистически значительно отличается от нормального (тест Шапиро–Уилка, $p < 0,001$), в связи с чем для сравнения данных выбраны непараметрические методы. Распределение исходных значений DSC по категориям PI-RADS представлено в табл. 2.

Результаты корреляционного анализа зависимости согласованности сегментации (значение DSC) от степени выраженности патологического процесса (категория PI-RADS) демонстрируют наличие слабой положительной статистически значимой связи ($\rho=0,3$ при $p=0,01$): чем выше категория по PI-RADS, тем выше согласованность масок разметки.

Результаты статистического анализа после пересмотра демонстрируют исчезновение статистически значимой связи между категорией очага и значением DSC ($\rho=0,09$ при $p=0,42$). Таким образом, применение разработанного алгоритма консенсусной разметки приводит к устранению вариабельности согласованности сегментации и повышению значений DSC , включая очаги категории PI-RADS 3 с нечёткими контурами.

Проведено статистическое сопоставление значений DSC на исходной выборке и новых данных (рис. 6, а): медианное значение DSC статистически значительно возросло после применения консенсуса (односторонний парный тест Вилкоксона, $p=0,01$). Корреляционный анализ зависимости модуля разности исходного и нового значения DSC от категории PI-RADS (см. рис. 6, б) показал наличие статистически значимой слабой отрицательной связи ($\rho=0,2$ при $p=0,04$). Таким образом, с повышением категории PI-RADS наблюдают уменьшение абсолютного прироста DSC .

ОБСУЖДЕНИЕ

РЕЗЮМЕ ОСНОВНОГО РЕЗУЛЬТАТА ИССЛЕДОВАНИЯ

Разработан и апробирован алгоритм разметки патологических очагов предстательной железы, позволяющий стандартизировать и сделать прозрачным процесс достижения консенсуса.

Изучена согласованность экспертов при ручной разметке патологических очагов предстательной железы. Применение алгоритма консенсусной разметки обеспечило статистически значимый ($p=0,01$) прирост значения DSC .

Применение алгоритма консенсусной разметки позволило достичь инвариантности согласованности сегментации: слабая положительная связь между категорией PI-RADS патологического очага и значением DSC , выявленная в исходной выборке, отсутствует в выборке, полученной после пересмотра случаев с использованием разработанного алгоритма. Большая часть случаев, подлежащих пересмотру, принадлежала к категориям PI-RADS 3 и 4 (74%).

ОБСУЖДЕНИЕ ОСНОВНОГО РЕЗУЛЬТАТА ИССЛЕДОВАНИЯ:

В данной работе представлена методология алгоритмизации консенсусной разметки очаговых изменений предстательной железы. Необходимость создания такого алгоритма обусловлена, во-первых, отсутствием в мировой литературе регламентированных правил достижения консенсуса; во-вторых, актуальностью подготовки наборов данных для различных целей, в частности для построения и валидации радиомических моделей.

Разработанный алгоритм направлен в первую очередь на сегментацию объектов с низкой контрастностью относительно окружающих тканей [20], в данном случае — очаговые изменения предстательной железы. Применение алгоритмов для их автоматической сегментации в рутинной практике ограничено, в особенности для неопределённых очагов категории PI-RADS 3.

Ручной метод сегментации очагов предстательной железы характеризуется высокой операторской зависимостью, что подтверждено результатами нашей работы (DSC — 0,61 [0,48; 0,73]), которые согласуются с данными упомянутых выше исследований [9, 10]. По результатам подгруппового анализа исходной выборки определяется наличие слабой положительной зависимости между значением DSC и категорией PI-RADS патологического очага ($\rho=0,3$ при $p=0,01$), то есть с повышением градации и контрастности [4] очага отмечается небольшое увеличение согласованности экспертов. Тем не менее даже для очагов с высоким риском клинически значимого рака показатели DSC сохраняются весьма умеренными (см. табл. 2). Применение радиомического анализа наиболее целесообразно для очагов предстательной железы с сомнительной вероятностью клинически значимого рака (PI-RADS 3), являющихся самыми сложными объектами для сегментации. Именно поэтому полученные результаты подчёркивают необходимость разработки новых подходов к разметке подобных очагов, направленных на снижение операторской зависимости метода.

Высокая вариабельность масок, полученных при сегментации несколькими экспертами, затрудняет обеспечение воспроизводимости текстурных показателей [8]. В связи с этим с целью её минимизации и получения «золотого стандарта» (Ground Truth) необходимо участие нескольких разметчиков с последующим формированием консенсуса.

В мировом научном сообществе не представлено стандартизированных протоколов по консенсусной разметке. Зачастую описание процесса достижения согласия ограничивается упоминанием термина «консенсус» без дальнейших разъяснений, как именно происходил выбор границ маски [13–15]. Так, в исследовании R. Suocolo и соавт. [13] в сложных случаях приглашали дополнительного эксперта, который мог при необходимости скорректировать предложенные маски или создать новые. Данный подход полностью зависит от квалификации приглашённого специалиста и оставляет простор для субъективных решений, не подвергаемых проверке и сомнению.

В вышеупомянутых рекомендациях ESR и EORTC [12] предлагают подход, заключающийся в поочерёдной коррекции одной маски двумя или более экспертами до предполагаемого момента формирования консенсуса. Очевидными ограничениями этого метода являются отсутствие указания необходимого числа итераций и чётких критериев того, какую маску можно считать итоговой.

В исследовании В. Косак и соавт. [21] с целью оценки воспроизводимости радиомических признаков применён подход итеративной коррекции для формирования консенсусных масок при анализе патологических образований гипофиза, молочных желёз и почек. В нём принимали участие 12 рентгенологов с различным опытом работы, при этом врачи с большим медицинским стажем корректировали маски менее опытных коллег. Именно поэтому финальное решение оставалось за наиболее опытным врачом (заведующим отделением лучевой диагностики). Однако, по данным М.У. Chen и соавт. [9], значение DSC сильно варьировало даже у опытных врачей-рентгенологов, что позволяет выдвинуть гипотезу о важности именно опыта разметки биомедицинских изображений по сравнению со стажем работы по субспециальности [12].

Отличительной особенностью разработанного алгоритма является подробная документация всех этапов консенсусной разметки, которая делает процесс сегментации прозрачным и понятным для врачей-рентгенологов. Помимо этого, отсутствие необходимости в привлечении дополнительных экспертов снижает риск предвзятости и повышает воспроизводимость разметки. Применение алгоритма позволяет добиться статистически значимого увеличения согласия между разметчиками: медианное значение DSC возросло с 0,61 до 0,74 при использовании консенсусной разметки. Ожидаемо, большую часть пересмотренных случаев (78%) составили очаги, относящиеся к категориям PI-RADS 3 и 4. Статистически значимый прирост значения DSC для всей выборки и для данных категорий, подтверждается результатами сопоставления групп и корреляционным анализом (см. рис. 5). Разработанный алгоритм может стать удобным инструментом для сегментации медицинских изображений при подготовке наборов данных.

Для определения оптимальной продолжительности периода «забывания» с целью его возможного сокращения необходимы отдельные исследования. По нашим данным, в отечественной и

зарубежной литературе отсутствуют работы, посвящённые изучению периода «забывания» в контексте сегментации биомедицинских изображений.

ОГРАНИЧЕНИЯ ИССЛЕДОВАНИЯ

Наше исследование имеет несколько ограничений:

- во-первых, пороговое значение DSC установлено на уровне 0,75 с учётом экспертного мнения коллектива авторов, в условиях отсутствия референсных значений по данным литературных исследований;
- во-вторых, период «забывания» продолжительностью в один месяц не позволяет полностью исключить предвзятости экспертов;
- в-третьих, мы не смогли полностью избежать этапа свободного обсуждения в одном из сценариев алгоритма, когда эксперты отвергают обе маски. Возможным вариантом решения данной проблемы, при наличии временных ресурсов, может стать повторное прохождение алгоритма для подобных очагов.
- в-четвёртых, в исследовании принимали участие всего два врача-рентгенолога, поэтому необходимо проведение дальнейшего тестирования алгоритма с участием большего количества специалистов, в том числе на объектах других анатомических локализаций.

Помимо этого, при анализе опубликованных работ, посвящённых радиомическому анализу и сегментации изображений лучевой диагностики, отмечают неоднозначное толкование термина «консенсус» разными авторами. Методам консенсуса в системе здравоохранения посвящена публикация J. Jones и соавт. [22], где указано, что его целью является определение степени согласия группы экспертов по конкретной теме или проблеме. К одному из важнейших качеств его методов относят анонимность, позволяющую избежать доминирования мнения одного из участников. Другими ключевыми характеристиками методов консенсуса являются итеративность процесса, предоставление ответов других экспертов и наличие обратной связи. Исходя из этого определения, применяемые в сегментации медицинских изображений методы консенсуса не в полной мере соответствуют заявленным качествам, в частности принципу анонимности. Таким образом, можно сделать вывод, что в разметке медицинских изображений, включая наше исследование, использованы лишь различные вариации консенсус-подобных методов.

ЗАКЛЮЧЕНИЕ

Разработанный алгоритм достижения консенсуса при ручной сегментации очаговых изменений предстательной железы подробно документирует каждый этап и способствует снижению субъективного влияния разметчиков на конечный результат за счёт исключения этапа, когда финальное решение принимает только один эксперт. Данный алгоритм может стать полезным инструментом в исследованиях по текстурному анализу и помочь внедрению радиомики в рутинную практику. Помимо этого, он демонстрирует необходимость разработки новых подходов к сегментации биомедицинских изображений, снижающих влияние человеческого фактора. Полученные результаты в очередной раз подтверждают высокую оператор-зависимость ручного метода при сегментации патологических очагов предстательной железы. Вместе с тем с повышением категории PI-RADS наблюдают небольшое увеличение согласованности между экспертами.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Вклад авторов. М.О. Романенко — написание текста рукописи, анализ данных; М.Р. Коденко — статистический анализ; П.Б. Гележе — сбор и анализ данных; И.А. Блохин — концепция и дизайн исследования, анализ данных, редактирование текста рукописи; Р.В. Решетников — редактирование текста рукописи. Все авторы одобрили рукопись (версию для публикации), а также согласились нести ответственность за все аспекты работы, гарантируя надлежащее рассмотрение и решение вопросов, связанных с точностью и добросовестностью любой её части.
Этическая экспертиза. Проведение исследования одобрено независимым этическим комитетом при ГБУЗ «НПКЦ ДиТ ДЗМ» (протокол заседания №06/2025 от 19.06.2025).

Источник финансирования. Данная статья подготовлена авторским коллективом в рамках научно-исследовательской работы «Научное обоснование методов лучевой диагностики опухолевых заболеваний с использованием радиомического анализа», (ЕГИСУ: № 123031500005-2) в соответствии с Приказом от 21.12.2022 № 1196 «Об утверждении государственных заданий,

финансовое обеспечение которых осуществляется за счёт средств бюджета города Москвы государственным бюджетным (автономным) учреждениям подведомственным Департаменту здравоохранения города Москвы, на 2023 год и плановый период 2024 и 2025 годов» Департамента здравоохранения города Москвы.

Раскрытие интересов. Авторы заявляют об отсутствии отношений, деятельности и интересов за последние три года, связанных с третьими лицами (коммерческими и некоммерческими), интересы которых могут быть затронуты содержанием статьи.

Оригинальность. При создании настоящей работы авторы не использовали ранее опубликованные сведения (текст, иллюстрации, данные).

Доступ к данным. Редакционная политика в отношении совместного использования данных к настоящей работе не применима.

Генеративный искусственный интеллект. При создании настоящей статьи технологии генеративного искусственного интеллекта не использовали.

Рассмотрение и рецензирование. Настоящая работа подана в журнал в инициативном порядке и рассмотрена по обычной процедуре. В рецензировании участвовали два внешних рецензента, один член редакционной коллегии и научный редактор издания.

СПИСОК ЛИТЕРАТУРЫ | REFERENCES

1. Smith CP, Harmon SA, Barrett T, et al. Intra- and interreader reproducibility of PI-RADSv2: a multireader study. *Journal of Magnetic Resonance Imaging*. 2018;49(6):1694–1703. doi: [10.1002/jmri.26555](https://doi.org/10.1002/jmri.26555)

2. Vasilev YuA, Omelyanskaya OV, Vladzimirskyy AV, et al. Comparison of multiparametric and biparametric magnetic resonance imaging protocols for prostate cancer diagnosis by radiologists with different experience. *Digital Diagnostics*. 2023;4(4):455–466. doi: [10.17816/dd322816](https://doi.org/10.17816/dd322816) EDN: [PVEPWX](#)

3. Borghesi M, Ahmed H, Nam R, et al. Complications after systematic, random, and image-guided prostate biopsy. *European Urology*. 2017;71(3):353–365. doi: [10.1016/j.eururo.2016.08.004](https://doi.org/10.1016/j.eururo.2016.08.004) EDN: [YXGSZX](#)

4. Nikolaev AE, Blohin IA, Shapiev AN, et al. *Application of the PI-RADS system in MR diagnostics of the prostate gland: methodological recommendations*. Moscow: Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies; 2019. (In Russ.) EDN: [TTGQTA](#)

5. Zhong J, Lu J, Zhang G, et al. An overview of meta-analyses on radiomics: more evidence is needed to support clinical translation. *Insights into Imaging*. 2023;14(1):111. doi: [10.1186/s13244-023-01437-2](https://doi.org/10.1186/s13244-023-01437-2) EDN: [SMPQCJ](#)

6. Chiacchio G, Castellani D, Nedbal C, et al. Radiomics vs radiologist in prostate cancer. Results from a systematic review. *World Journal of Urology*. 2023;41(3):709–724. doi: [10.1007/s00345-023-04305-2](https://doi.org/10.1007/s00345-023-04305-2) EDN: [HPNNUD](#)

7. Telecan T, Andras I, Crisan N, et al. More than meets the eye: using textural analysis and artificial intelligence as decision support tools in prostate cancer diagnosis—a systematic review. *Journal of Personalized Medicine*. 2022;12(6):983. doi: [10.3390/jpm12060983](https://doi.org/10.3390/jpm12060983) EDN: [TIZZEK](#)

8. Whybra P, Spezi E. Sensitivity of standardised radiomics algorithms to mask generation across different software platforms. *Scientific Reports*. 2023;13(1):14419. doi: [10.1038/s41598-023-41475-w](https://doi.org/10.1038/s41598-023-41475-w) EDN: [LVNVNQ](#)

9. Chen MY, Woodruff MA, Dasgupta P, Rukin NJ. Variability in accuracy of prostate cancer segmentation among radiologists, urologists, and scientists. *Cancer Medicine*. 2020;9(19):7172–7182. doi: [10.1002/cam4.3386](https://doi.org/10.1002/cam4.3386) EDN: [LCYCRN](#)

10. Jeganathan T, Salgues E, Schick U, et al. Inter-rater variability of prostate lesion segmentation on multiparametric prostate MRI. *Biomedicine*. 2023;11(12):3309. doi: [10.3390/biomedicine11123309](https://doi.org/10.3390/biomedicine11123309) EDN: [ZCDYWR](#)

11. Ghafoor S, Steinebrunner F, Stocker D, et al. Index lesion contouring on prostate MRI for targeted MRI/US fusion biopsy – Evaluation of mismatch between radiologists and urologists. *European Journal of Radiology*. 2023;162:110763. doi: [10.1016/j.ejrad.2023.110763](https://doi.org/10.1016/j.ejrad.2023.110763) EDN: [QLSWGX](#)

12. deSouza NM, van der Lugt A, Deroose CM, et al; European Society of Radiology. Standardised lesion segmentation for imaging biomarker quantitation: a consensus recommendation from ESR and EORTC. *Insights into Imaging*. 2022;13(1):159. doi: [10.1186/s13244-022-01287-4](https://doi.org/10.1186/s13244-022-01287-4) EDN: [ONUHSE](#)

13. Cuocolo R, Stanzione A, Ponsiglione A, et al. Clinically significant prostate cancer detection on MRI: a radiomic shape features study. *European Journal of Radiology*. 2019;116:144–149. doi: [10.1016/j.ejrad.2019.05.006](https://doi.org/10.1016/j.ejrad.2019.05.006) EDN: [XBKHNN](#)
14. Cuocolo R, Comelli A, Stefano A, et al. Deep learning whole-gland and zonal prostate segmentation on a public MRI dataset. *Journal of Magnetic Resonance Imaging*. 2021;54(2):452–459. doi: [10.1002/jmri.27585](https://doi.org/10.1002/jmri.27585) EDN: [GNOJHL](#)
15. Schelb P, Kohl S, Radtke JP, et al. Classification of cancer at prostate MRI: deep learning versus clinical PI-RADS assessment. *Radiology*. 2019;293(3):607–617. doi: [10.1148/radiol.2019190938](https://doi.org/10.1148/radiol.2019190938)
16. Kocak B, Akinci D'Antonoli T, Mercaldo N, et al. METHodological RadiomIcs Score (METRICS): a quality scoring tool for radiomics research endorsed by EuSoMII. *Insights into Imaging*. 2024;15(1):8. doi: [10.1186/s13244-023-01572-w](https://doi.org/10.1186/s13244-023-01572-w) EDN: [CINMDC](#)
17. Murre JMJ, Chessa AG. Why Ebbinghaus' savings method from 1885 is a very 'pure' measure of memory performance. *Psychon Bull Rev*. 2023;30(1):303–307. doi: [10.3758/s13423-022-02172-3](https://doi.org/10.3758/s13423-022-02172-3)
18. Chow S.-C., Wang H., Shao J. *Sample Size Calculations in Clinical Research* (2nd ed.). Chapman and Hall/CRC. – 2007.
19. Blokhin IA, Kodenko MR, Shumskaya YF, et al. Hypothesis testing using R. *Digital Diagnostics*. 2023;4(2):238–247. doi: [10.17816/DD121368](https://doi.org/10.17816/DD121368) EDN: [OEKDAG](#)
20. Kallie CS, Legge GE, Yu D. Identification and detection of simple 3D objects with severely blurred vision. *Investigative Ophthalmology & Visual Science*. 2012;53(13):7997. doi: [10.1167/iovs.12-10013](https://doi.org/10.1167/iovs.12-10013)
21. Kocak B, Yardimci AH, Nazli MA, et al. REliability of consensus-based segMentatioN in raDiomic feature reproducibility (REMIND): A word of caution. *European Journal of Radiology*. 2023;165:110893. doi: [10.1016/j.ejrad.2023.110893](https://doi.org/10.1016/j.ejrad.2023.110893) EDN: [VBDFCG](#)
22. Jones J, Hunter D. Qualitative Research: Consensus methods for medical and health services research. *BMJ*. 1995;311(7001):376–380. doi: [10.1136/bmj.311.7001.376](https://doi.org/10.1136/bmj.311.7001.376) EDN: [CBNBSJ](#)

ОБ АВТОРАХ/ AUTHORS' INFO

Автор, ответственный за переписку:	
* Романенко Мария Олеговна ; адрес: Россия, 127051, Москва, ул. Петровка, д. 24, стр. 1; ORCID: 0009-0006-1557-0374; e-mail: RomanenkoMO@zdrav.mos.ru	* Maria O. Romanenko ; address: 24 Petrovka st, bldg 1, Moscow, Russia, 127051; ORCID: 0009-0006-1557-0374; e-mail: RomanenkoMO@zdrav.mos.ru
Соавторы (должны быть приведены в порядке их перечисления в списке авторов рукописи):	
Коденко Мария Романовна , канд. техн. наук; ORCID: 0000-0002-0166-3768; eLibrary SPIN: 5789-0319; e-mail: KodenkoM@zdrav.mos.ru	Maria R. Kodenko , Cand. Sci. (Engineering); ORCID: 0000-0002-0166-3768; eLibrary SPIN: 5789-0319; e-mail: KodenkoM@zdrav.mos.ru
Гелезе Павел Борисович , канд. мед. наук; ORCID: 0000-0003-1072-2202 eLibrary SPIN: 4841-3234; e-mail: gelezhe.pavel@gmail.com	Pavel B. Gelezhe , MD, Cand. Sci. (Medicine); ORCID: 0000-0003-1072-2202; eLibrary SPIN: 4841-3234; e-mail: gelezhe.pavel@gmail.com
Блохин Иван Андреевич , канд. мед. наук; ORCID: 0000-0002-2681-9378; eLibrary SPIN: 3306-1387; e-mail: BlokhinIA@zdrav.mos.ru	Ivan A. Blokhin , MD, Cand. Sci. (Medicine); ORCID: 0000-0002-2681-9378; eLibrary SPIN: 3306-1387; e-mail: BlokhinIA@zdrav.mos.ru
Решетников Роман Владимирович , канд. физ.-мат. наук; ORCID: 0000-0002-9661-0254; eLibrary SPIN: 8592-0558; e-mail: ReshetnikovRV1@zdrav.mos.ru	Roman V. Reshetnikov , Cand. Sci. (Physics and Mathematics); ORCID: 0000-0002-9661-0254; eLibrary SPIN: 8592-0558; e-mail: ReshetnikovRV1@zdrav.mos.ru

ТАБЛИЦЫ

Таблица 1. Нулевые и альтернативные гипотезы исследования

Нулевая гипотеза (H ₀)	Альтернативная гипотеза (H _a)
Значение DSC при разметке очагов предстательной железы двумя экспертами будет меньше 0,75 ¹	Значение DSC при разметке очагов предстательной железы двумя экспертами будет больше или равно 0,75 ¹
Коэффициент корреляции между DSC и категорией PI-RADS очага статистически значимо не отличается от нуля	Коэффициент корреляции между DSC и категорией PI-RADS очага статистически значимо отличается от нуля

Примечание. 1 — обоснование выбранного пограничного значения отображено в разделе «Материалы и методы»; DSC (Dice-Sorensen Similarity Coefficient) — коэффициент сходства Сёренсена–Дайса; PI-RADS (Prostate Imaging-Reporting and Data System) — система визуализации, описания и оценки изображений предстательной железы.

Таблица 2. Распределение исходных значений коэффициента сходства Сёренсена–Дайса в зависимости от категории PI-RADS патологических очагов

Категория PI-RADS	Коэффициент сходства Сёренсена–Дайса
PI-RADS 3 (вероятность наличия клинически значимого рака остаётся неопределённой)	0,54 [0,37; 0,67]
PI-RADS 4 (высокая вероятность клинически значимого рака)	0,61 [0,52; 0,71]
PI-RADS 5 (очень высокая вероятность клинически значимого рака)	0,68 [0,59; 0,76]

Примечание. Данные представлены в виде Me [Q1; Q3], где Me — медиана, Q1 и Q3 — 1- и 3-й квартиль соответственно; PI-RADS (Prostate Imaging-Reporting and Data System) — система визуализации, описания и оценки изображений предстательной железы

РИСУНКИ

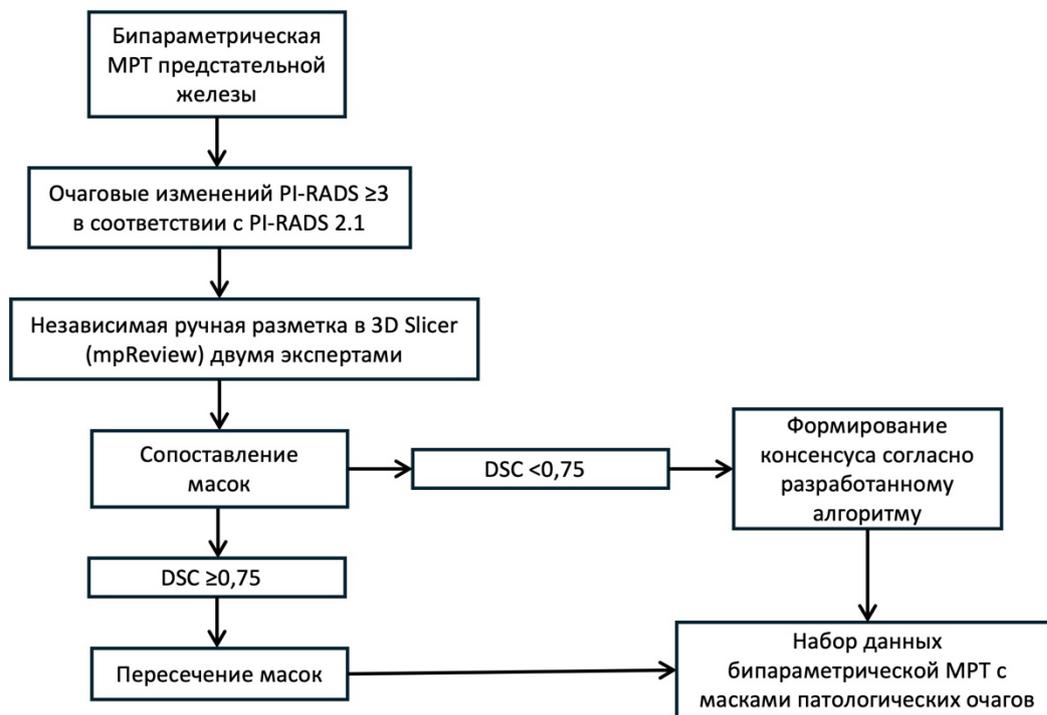


Рис. 1. Дизайн исследования. МРТ — магнитно-резонансная томография; DSC (Dice-Sørensen Similarity Coefficient) — коэффициент сходства Сёренсена–Дайса; PI-RADS (Prostate Imaging-Reporting and Data System) — система визуализации, описания и оценки изображений предстательной железы; mpReview (Multiparametric Review) — расширение программного обеспечения для анализа и сегментации мультипараметрических исследований.

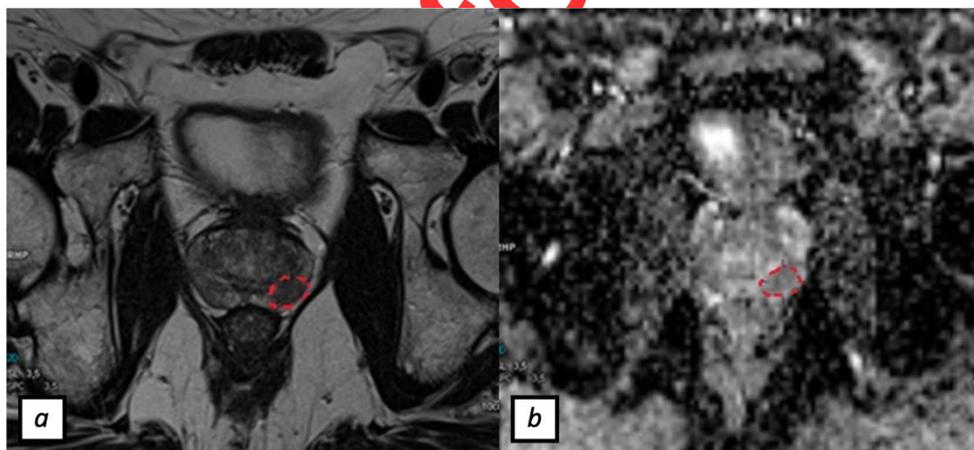


Рис. 2. Референсные изображения со схематически отмеченным очагом в периферической зоне левой доли предстательной железы: а — T2-взвешенное изображение; б — карта исчисляемого коэффициента диффузии.

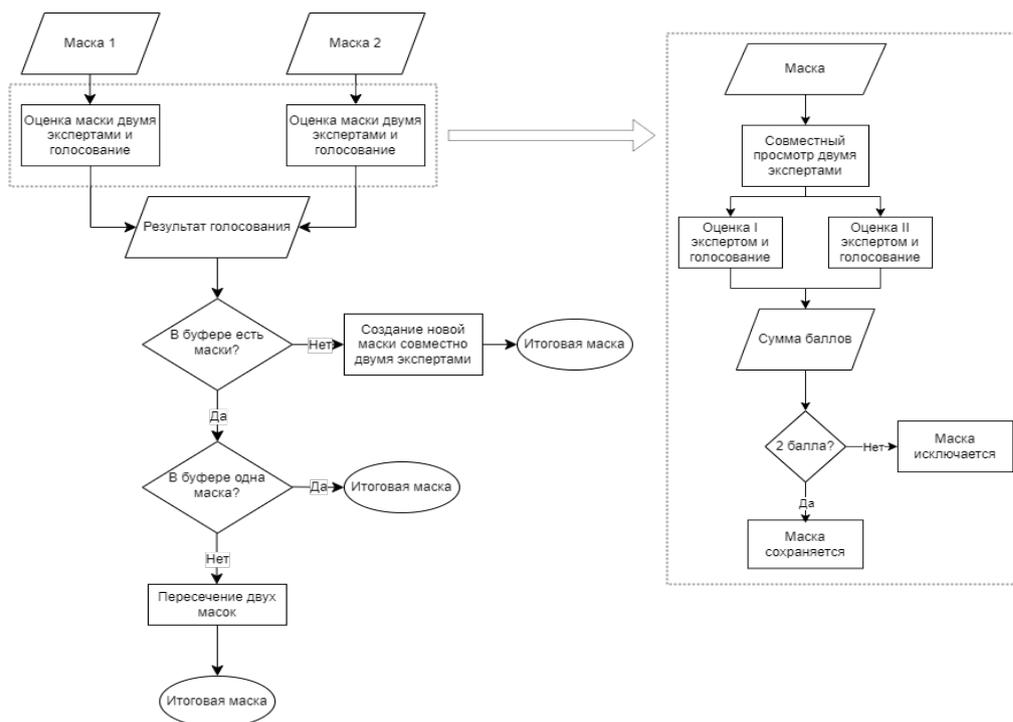


Рис. 3. Алгоритм достижения консенсуса.

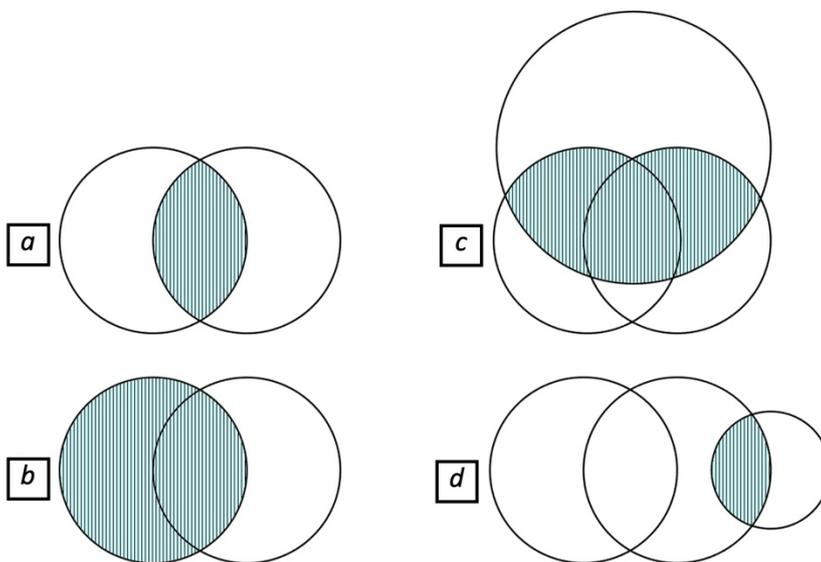


Рис. 4. Расчёт коэффициент сходства Сёрнсена-Дайса после прохождения алгоритма: *a* — если эксперты выбрали обе маски (сохраняется первичный коэффициент сходства Сёрнсена-Дайса); *b* — если выбрана одна из двух масок; *c* — новая маска имеет пересечение с двумя предыдущими; *d* — новая маска пересекается только с одной из предыдущих масок.

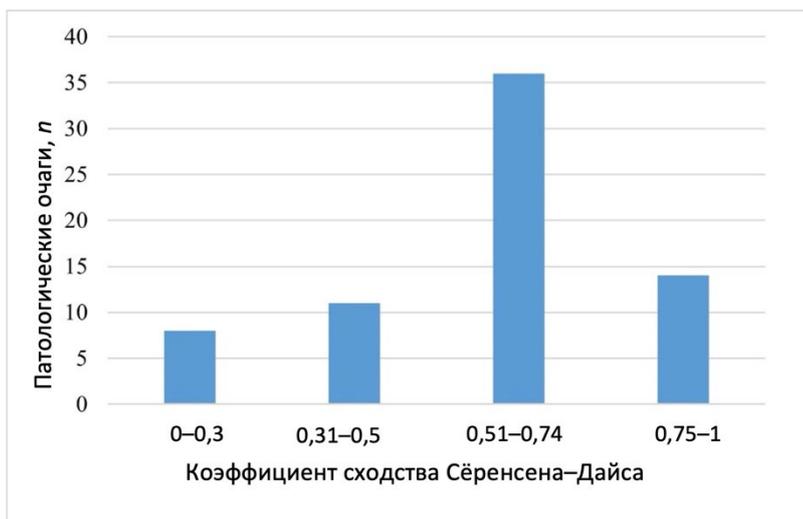


Рис. 5. Распределение исходных значений коэффициента сходства Сёрнсена-Дайса.

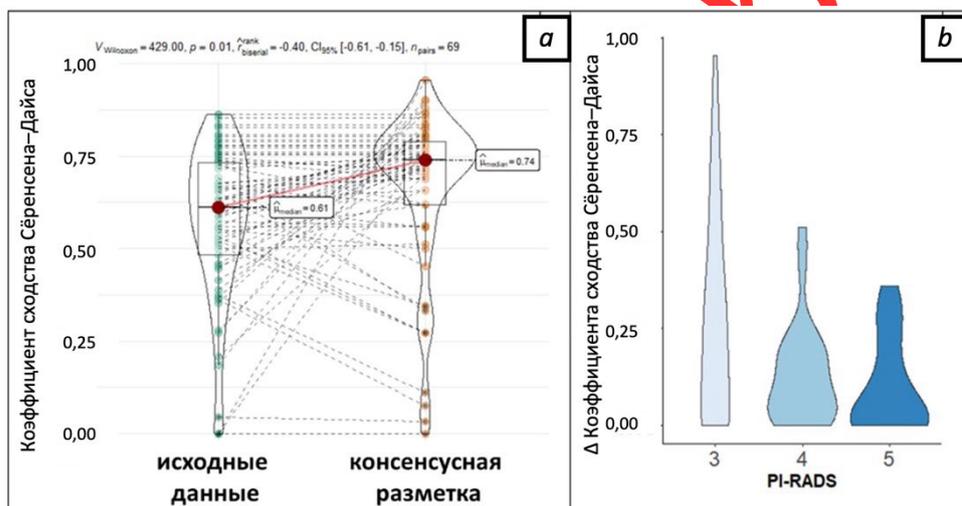


Рис. 6. Сопоставление значений коэффициента сходства Сёрнсена-Дайса до и после применения алгоритма консенсусной разметки: *a* — сравнение медиан; *b* — связь с категорией PI-RADS. PI-RADS (Prostate Imaging-Reporting and Data System) — система визуализации, описания и оценки изображений предстательной железы.