

ОЦЕНКА ВОЗМОЖНОСТЕЙ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ И РАДИОМИЧЕСКОГО АНАЛИЗА ДЛЯ ДИФФЕРЕНЦИАЛЬНОЙ ДИАГНОСТИКИ КИСТОЗНЫХ НОВООБРАЗОВАНИЙ ПОДЖЕЛУДОЧНОЙ ЖЕЛЕЗЫ

Карпов С.С.¹, Кондратьев Е.В.², Усталов А.А.², Шмелева С.А.²✉, Тарнопольский В.М.²

¹ Городская поликлиника № 220 Департамента здравоохранения Москвы; Россия, 123022, Москва, ул. Загорёнова, 27.

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

✉ Шмелева София Антоновна, sofiyaantonovna@gmail.com, 89201193033

РЕФЕРАТ

Актуальность: Дифференциальная диагностика кистозных образований поджелудочной железы имеет решающее значение для выбора оптимальной тактики лечения и предотвращения прогрессирования заболевания. В связи с этим актуальной задачей современной лучевой диагностики является разработка и внедрение новых методов, которые могут повысить точность диагностики и снизить зависимость от субъективной интерпретации данных.

Цель: Исследование возможностей МРТ и радиомического анализа МРТ-изображений в дифференциальной диагностике кистозных новообразований поджелудочной железы, а также разработка радиомических моделей на основе машинного обучения для определения злокачественного потенциала кистозных образований поджелудочной железы.

Материалы и методы: Ретроспективно были проанализированы МРТ-изображения 67 пациентов с верифицированными (по результатам оперативного вмешательства) кистозными новообразованиями поджелудочной железы. Разметку и извлечение радиомических признаков исследований проводил врач-рентгенолог с опытом абдоминальной визуализации и выполнения разметки патологий поджелудочной железы. Образования были разделены для бинарной задачи классификации. Было использовано 7 моделей машинного обучения. Эффективность моделей оценивалась с помощью различных метрик (ROC-AUC, PR-AUC, точность, чувствительность, специфичность, F1). Наилучшая модель была определена по результатам ROC-AUC.

Результаты: Наилучшие результаты показали алгоритмы Random Forest с ROC-AUC = 0.83, и LightGBM с ROC-AUC = 0.77. Анализ SHAP выявил ключевые радиомические признаки.

Выводы: Полученные результаты демонстрируют перспективность данного подхода и служат основанием для проведения дальнейших исследований, направленных на повышение точности и обобщаемости моделей.

Ключевые слова: кистозные новообразования поджелудочной железы, дифференциальная диагностика, МРТ, радиомика, машинное обучение, радиомический анализ

Для цитирования: Карпов С.С., Кондратьев Е.В., Усталов А.А., Шмелева С.А., Тарнопольский В.М. Оценка возможностей моделей машинного обучения и радиомического анализа для дифференциальной диагностики кистозных новообразований поджелудочной железы. Онкологический журнал: лучевая диагностика, лучевая терапия. 2026;9(1):43-52.

<https://doi.org/10.37174/2587-7593-2026-9-1-43-52>

RADIOMICS-BASED MACHINE LEARNING MODEL FOR DIFFERENTIAL DIAGNOSIS OF PANCREATIC CYSTIC NEOPLASMS

Sergey S. Karpov¹, Evgeny V. Kondratyev², Andrei A. Ustalov², Sofiya A. Shmeleva²✉, Vitaliy M. Tarnopolsky²

¹ City Polyclinic No. 220, Moscow Health Department; 27 Zamorenova St., Moscow 123022, Russia.

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

✉ Sofiya A. Shmeleva, sofiyaantonovna@gmail.com, 89201193033

ABSTRACT

Introduction: Accurate differential diagnosis of pancreatic cystic lesions is crucial for selecting the optimal management strategy and for timely identification of lesions with malignant potential. A key objective of radiology is the development and implementation of quantitative imaging approaches that can improve diagnostic performance and reduce reliance on subjective image interpretation.

Purpose: To evaluate the value of magnetic resonance imaging (MRI) and MRI-based radiomic analysis for the differential diagnosis of pancreatic cystic neoplasms, and to develop machine-learning radiomic models for predicting the malignant potential of pancreatic cystic lesions.

Materials and methods: In this retrospective study, MRI examinations of 67 patients with surgically and pathologically confirmed pancreatic cystic neoplasms were analyzed. Lesion segmentation and radiomic feature extraction were performed by a radiologist experienced in abdominal imaging. Seven supervised machine-learning models were trained. Model performance was assessed using area under the receiver operating characteristic curve (ROC-AUC), precision-recall AUC (PR-AUC), accuracy, sensitivity, specificity, and F1-score. The best-performing model was selected based on ROC-AUC. Model interpretability was evaluated using SHapley Additive exPlanations (SHAP).

Results: The Random Forest classifier showed the best performance (ROC-AUC = 0.83), followed by LightGBM (ROC-AUC = 0.77). SHAP analysis highlighted the radiomic features with the greatest impact on the model outputs.

Conclusion: MRI-based radiomics may support risk stratification of pancreatic cystic lesions. Further studies with larger cohorts are needed to confirm these findings and improve model generalizability.

Key words: pancreatic cystic neoplasms, differential diagnosis, MRI, radiomics, machine learning

For citation: Karpov S.S., Kondratyev E.V., Ustalov A.A., Shmeleva S.A., Tarnopolsky V.M. Radiomics-Based Machine Learning Model for Differential Diagnosis of Pancreatic Cystic Neoplasms. Journal of Oncology: Diagnostic Radiology and Radiotherapy. 2026;9(1):43-52. (In Russ.). <https://doi.org/10.37174/2587-7593-2026-9-1-43-52>

Введение

Кистозные новообразования поджелудочной железы (КОПЖ) являются достаточно частой находкой, при этом с возрастом их распространенность, количество и размеры увеличиваются. Около 50 % выявленных кистозных образований выявляют при проведении лучевого обследования по поводу других состояний. Распространенность КОПЖ 4–14 %. Клиническая картина кистозных образований неспецифична, многие из них бессимптомны, что еще больше затрудняет диагностику, при этом 75 % основных гистологических типов образований имеют злокачественный потенциал и, соответственно, различные подходы к лечению. Современные рекомендации по диагностике КОПЖ ограничены, что приводит либо к пропуску патологии, либо к неверной тактике лечения. Резекция КОПЖ должна выполняться крайне избирательно, учитывая риск осложнений 20–40 % и летальность ~2 % после операций на поджелудочной железе [1].

Кистозные образования подразделяются на эпителиальные и неэпителиальные, и каждая из этих категорий дополнительно подразделяется на неопухолевые и опухолевые.

Эпителиальные кистозные опухолевые новообразования поджелудочной железы классифицируют на муцинозные, которые являются предраковыми или злокачественными, и немучинозные новообразования, к которым относятся как доброкачественные (наиболее распространённые), так и пограничные и злокачественные опухоли.

В частности, к муцинозным кистозным новообразованиям ПЖ относятся муцинозные кистозные новообразования и внутрипротоковые папиллярные муцинозные новообразования (ВПМН), а к немучинозным — серозные кистозные новообразования, солидные псевдопапиллярные образования (СППО), кистозные нейроэндокринные новообразования, более редкие ацинарно-клеточные кистозные новообразования, протоковые аденокарциномы с кистозной дегенерацией и другие образования.

Так, ВПМН — подтип КОПЖ с одним из самых высоких рисков малигнизации. Для главного протока поджелудочной железы риск составляет 38–68 %, для боковых ветвей — 12–47 % [2].

ВПМН являются наиболее распространёнными кистозными неоплазиями поджелудочной железы. Они характеризуются продукцией густого муцина и чаще локализируются в головке поджелудочной железы. ВПМН подразделяются на три типа: поражающие главный панкреатический проток, исходящие из боковых ветвей панкреатических протоков, а также смешанный вариант, сочетающий признаки обоих типов. Дифференциация между типами имеет важное клиническое значение, поскольку ВПМН бо-

ковых ветвей обладают более низким потенциалом малигнизации и требуют различной тактики ведения по сравнению с другими типами, для которых риск злокачественной трансформации и подходы к лечению сопоставимы [3].

Ключевым фактором для характеристики ВПМН является установление того, сообщается ли поражение с главным протоком поджелудочной железы или нет. Магнитно-резонансная холангиопанкреатография (МРХПГ) — лучший метод визуализации для оценки связи с главным панкреатическим протоком (ГПП), что является ключевым фактором для определения типа КОПЖ [2].

Муцинозная цистаденома (МЦ) — редкая опухоль поджелудочной железы, преимущественно выявляемая у женщин среднего возраста. Как правило, она обнаруживается случайно и чаще локализуется в теле или хвосте поджелудочной железы. Муцинозная цистаденома характеризуется образованием муцин-продуцирующих кист, окружённых стромой овариального типа. По данным визуализирующих методов исследования, МЦ обычно представляют собой одиночные округлые образования, содержат густой муцин и/или геморрагический компонент. Возможно наличие периферической кальцификации, которая отличается от звездчатой кальцификации, характерной для серозных цистаденом [3].

Псевдокиста поджелудочной железы — доброкачественное новообразование, скопление жидкости в поджелудочной железе и/или перипанкреатической области с чётко очерченными стенками, содержащее панкреатический сок или жидкость с высоким содержанием амилазы. Псевдокиста считается отсроченным (обычно более 4 недель) осложнением интерстициального отёчного панкреатита.

При МРТ псевдокиста очень похожа на другие кисты поджелудочной железы, поэтому для постановки уверенного диагноза «псевдокиста» необходимо сопоставить результаты с анамнезом пациента (острый панкреатит в анамнезе). Цуй и соавт. (2014) в многоцентровом исследовании показали, что более 80 % псевдокист уменьшаются в размерах в ходе последующего наблюдения [2].

Однако стоит отметить, что острый панкреатит может быть вызван кистозными опухолями (например, ВПМН), или у пациентов с острым панкреатитом могут быть кистозные опухоли, поэтому перенесённый острый панкреатит не может полностью исключить наличие истинной кистозной опухоли.

Серозная цистаденома — это доброкачественное новообразование, и было опубликовано лишь несколько случаев его злокачественной трансформации [2].

Она состоит из множества кист, образованных богатыми гликогеном эпителиальными клетками,

и в основном поражает головку поджелудочной железы, хотя может возникать в любой части железы. В первую очередь это касается женщин в возрасте 50 лет, но часто заболевание обнаруживается и в более позднем возрасте.

В 15–30 % случаев серозная цистаденома ассоциирована с болезнью фон Гиппеля — Линдау, и в этих случаях, как правило, образование является мультифокальным и может диффузно поражать поджелудочную железу [2].

При визуализации серозная цистаденома может проявляться в трёх основных формах, отражающих его морфологию: микрокистозной (или поликистозной), ячеистой и макрокистозной (или олигокистозной).

Макрокистозный паттерн характеризуется небольшим количеством кист размером не менее 2 см без центрального рубца и часто неотличим от других кистозных поражений поджелудочной железы, особенно от муцинозных цистаденом и ВПМН боковых ветвей. Дифференциальная диагностика важна, поскольку серозная цистаденома является доброкачественным образованием, в то время как муцинозные цистаденомы и ВПМН боковых ветвей имеют потенциально злокачественный характер.

Дифференциальная диагностика кистозных образований поджелудочной железы имеет решающее значение для выбора оптимальной тактики лечения и предотвращения прогрессирования заболевания.

Наличие злокачественного потенциала кистозных неоплазий требует либо активной хирургической тактики, либо активного динамического наблюдения. Чтобы избежать необоснованного хирургического лечения, исключить случаи необоснованно затянутого наблюдения и для принятия правильной тактики ведения пациентов, необходимо точно верифицировать тип кистозной неоплазии. Оперативное лечение нередко ведет к снижению качества жизни пациента, в некоторых случаях — к инвалидизации, а затянутое наблюдение — к злокачественной трансформации новообразования. В настоящее время продолжают исследования и дискуссии по поводу объема хирургического пособия при различных вариантах кистозных неоплазий [1].

Согласно Европейским рекомендациям, МРТ — предпочтительный метод визуализации КОПЖ, однако КТ также может использоваться самостоятельно или в сочетании с МРТ для оценки кальцинатов, стадирования опухоли или диагностики послеоперационного рецидива. Дополнительно рекомендуется исследование уровня СЕА (carcinoembryonic antigen), амилазы/липазы в жидкости кистозного образования, а также цитологический анализ для достижения максимальной

точности в дифференциации муцинозных и немучинозных кист [3].

Между пятью широко используемыми клиническими рекомендациями существуют значительные расхождения относительно EUS/EUS-FNA и показаний к резекции, что свидетельствует об отсутствии стандартизации в диагностическом подходе: American College of Gastroenterology и European guideline включает все КОПЖ, критерии Fukuoka — только ВПМН, American Gastroenterological Association (AGA) не включает ВПМН главного протока. Сравнительные исследования показали ограниченную эффективность рекомендаций: руководство AGA (2015): точность 49,6 %, чувствительность 23,5 %, специфичность 84,3 %; критерии Fukuoka: 41,2 %, 39,7 %, 43,1 % соответственно; Европейские рекомендации (2018): 58 %, 67,7 %, 45,1 % [2].

В связи с этим актуальной задачей современной лучевой диагностики является разработка и внедрение новых методов, которые могут повысить точность диагностики и снизить зависимость от субъективной интерпретации данных.

Одним из таких методов является радиомика. В то время как с помощью биопсии возможно исследовать лишь небольшую часть опухоли и обычно только в одном анатомическом участке, с помощью радиомики возможно оценить всю опухоль, а также перитуморальную область и нормальную паренхиму. Так, в радиомике для решения различных диагностических задач из медицинских изображений получают количественные характеристики (радиомические признаки) и анализируют их, используя машинное обучение. Такой анализ большого количества признаков позволяет снизить субъективность современных методов диагностики [4].

Существует ограниченное количество исследований [5, 6] применения радиомического анализа для дифференциальной диагностики КОПЖ, однако мы считаем радиомику перспективным методом для этого направления диагностики.

В нашем исследовании мы разработали модель с использованием машинного обучения и радиомики для определения риска злокачественности КОПЖ, которая является заделом для внедрения радиомики в клиническую практику для повышения точности диагностики КОПЖ.

Цель работы — исследование возможностей радиомического анализа МРТ-изображений в дифференциальной диагностике кистозных новообразований поджелудочной железы, разработка радиомических моделей на основе машинного обучения для определения злокачественного потенциала кистозных образований поджелудочной железы.

Материалы и методы

Ретроспективно были проанализированы МРТ-изображения 67 пациентов с верифицированными по результатам оперативного вмешательства, проведенных в НМИЦ хирургии им. А.В. Вишневского в период с 2015 по 2024 год, кистозными новообразованиями поджелудочной железы. В исследование были включены пациенты с ВПМН, серозными макрокистозными цистаденомами, муцинозными цистаденомами, цистаденокарциномами и постнекротическими кистами. Пациентам было проведено МРТ-исследование в НМИЦ хирургии им. А.В. Вишневского или проведена консультация данных МРТ, представленных на диске из другой больницы.

Для построения бинарной модели все включённые кистозные образования были сгруппированы по принципу, отражающему злокачественный потенциал и тактику ведения пациента.

К классу 0 были отнесены злокачественные и потенциально злокачественные эпителиальные муцинозные неоплазии поджелудочной железы: ВПМН (включая ВПМН-карциномы), муцинозные кистозные новообразования (включая муцинозные цистаденомы и муцинозные цистаденокарциномы). Данная группа объединяет образования, которые требуют активной хирургической тактики.

Класс 1 сформирован из образований с преимущественно доброкачественным течением и отсутствием значимого злокачественного потенциала: серозных макрокистозных цистаденом и постнекротических кист. Эти поражения в типичных случаях не требуют резекции и подлежат наблюдению либо лечению по показаниям (симптоматика, осложнения, рост), что принципиально отличает их от муцинозных неоплазий.

Выбранный подход к разделению на группы обусловлен практическими задачами лучевой диагностики. Наибольшую клиническую и методологическую сложность представляет дифференциальная диагностика муцинозных кистозных новообразований и серозных макрокистозных цистаденом.

При формировании датасета мы исходили из предположения, что в большинстве кистозных поражений основной объём ROI представлен жидкостным компонентом, а значит, существенная часть извлекаемых радиомических признаков будет отражать количественные характеристики содержимого кисты, потенциально различающиеся для муцинозного и немучинозного содержимого. Следовательно, мы предположили возможность дифференциальной диагностики неоплазий преимущественно на основе характеристик внутрисодержимого.

Для повышения статистической мощности исследования и увеличения числа наблюдений в группах в бинарную схему дополнительно включены образования, репрезентирующие соответствующие биологические классы. ВПМН добавлены в класс 0 как муцинозные эпителиальные неоплазии с доказанным злокачественным потенциалом и клинической направленностью на хирургическое лечение/активную онкологическую настороженность. Постнекротические кисты включены в класс 1 как немучинозные, неопухолевые жидкостные образования, для которых типично доброкачественное течение. Тем самым классы 0 и 1 были сформированы не только по нозологическому признаку, но и по принципу «муцинозные (потенциально злокачественные, хирургически значимые) или немучинозные (преимущественно доброкачественные, наблюдаемые)», что соответствует ключевой диагностической задаче при ведении пациентов с кистозными образованиями поджелудочной железы и напрямую согласуется с целевой задачей модели — определение злокачественного потенциала. Микрокистозные серозные цистаденомы в настоящее исследование не включались. Микрокистозный вариант серозной цистаденомы, как правило, имеет характерный признаки (множественные мелкие кисты, «сотовая»/поликистозная структура, нередко центральный рубец), что в большинстве случаев позволяет уверенно предположить диагноз на основании данных МРТ или КТ и, следовательно, не представляет основной клинической проблемы дифференциальной диагностики.

Также включение микрокистозных серозных цистаденом могло бы привести к смещению модели в сторону распознавания преимущественно морфологических признаков (большое количество небольших кист и перегородок в структуре), тогда как концепция настоящей работы исходно ориентирована на гипотезу о высокой информативности количественных характеристик содержимого кистозного компонента. При микрокистозном строении сегментация зачастую включает значимый объём перегородок и стромального компонента, что уменьшает долю сигнала жидкости в ROI и повышает вариабельность радиомических признаков, снижая сопоставимость с олигокистозными образованиями.

МРТ-исследования были выполнены по стандартному протоколу с индукцией магнитного поля 1,5 и 3 Тл. Сканирование включало выполнение T₁- и T₂-взвешенных последовательностей без подавления и с подавлением сигнала от жира, DWI с последующим построением карт ADC. Для оценки протоковой системы ПЖ и желчевыводящих протоков проводили МРХПГ с использованием 3D T₂

сканов (TR — 1800 мс, TE — 470 мс). При этом параметры сканов T_2 , полученных с помощью импульсной последовательности TSE, были следующими: TR — 1600 мс, TE — 100 мс, а с помощью импульсной последовательности STIR: TR — 1600 мс, TE — 20 мс. Сканы T_1 получали при помощи импульсной последовательности FFE (TR — 181,7 мс, TE — 3,5 мс). Все программы выполнялись с триггерной синхронизацией с дыханием, за исключением T_1 с подавлением сигнала от жира (THRIVE), которая выполнялась на задержке дыхания.

Все клинические случаи, включенные в исследование, были завершены, все новообразования были верифицированы гистологически по результатам патоморфологического исследования операционного материала. Заключение патоморфологии хранятся в лабораторной информационной системе “ЛабФлоу”.

Плановое гистологическое исследование макро- и микропрепаратов проводилось по принятой в нашем Центре методике. Исследование материала выполняли сотрудники патологоанатомического отделения Института хирургии им. А.В. Вишневского Минздрава России, под руководством заведующего отделением к.м.н. Д.В. Калинина.

Окончательные диагнозы для консультированных в референс-центре НМИЦ хирургии случаев также были гистологически верифицированы.

Критерии включения:

- Гистологически верифицированное образование поджелудочной железы (ВПМН, серозные и муцинозные цистаденомы, цистаденокарциномы, постнекротические кисты).

- Наличие МР-исследования органов брюшной полости, наличие T_2 , T_1 -взвешенных последовательностей, ДВИ, карт ADC.

Критерии исключения:

- Неудовлетворительное качество МРТ-изображений, наличие артефактов.
- Невозможность провести сегментацию области интереса: малый размер образования, технические трудности.

Подготовка данных

Сегментация

Разметку исследований проводил врач-рентгенолог с опытом абдоминальной визуализации (3 года) и опытом выполнения разметки патологий поджелудочной железы (3 года). Вручную на каждом срезе или с использованием дополнительных инструментов (например, fill between slices и др.) были сегментированы образования поджелудочной железы на T_2 -ВИ, T_1 -ВИ, ДВИ на высоком и низком b -факторе, картах ADC в программе 3D Slicer (версия 5.6.2) (рис. 1).

Предварительная обработка и извлечение радиомических признаков

Для предварительной обработки и извлечения радиомических признаков данных был использован код, созданный с учетом рекомендаций IBSI [7]. В 3D Slicer (модуль Pyradiomics) были проведены обработка данных и извлечение радиомических признаков. Предварительная обработка необходима для стандартизации данных и повышения надежности извлекаемых радиомических признаков, что




Рис. 1. Сегментация кистозного образования поджелудочной железы в 3D Slicer.

1 — T_2 -ВИ, 2 — T_1 -ВИ,
3 — ADC карта, 4 — 3D модель

Fig. 1. Segmentation of a pancreatic cystic lesion in 3D Slicer.

1 — T_2 -weighted image,
2 — T_1 -weighted image,
3 — ADC map, 4 — 3D model

является критически важным для обеспечения воспроизводимости и обобщаемости моделей.

Интенсивности пикселей изображения были нормализованы (`normalizeScale: 100` — масштаб нормализации). Данный этап обычно необходим для МРТ-изображений, поскольку их сигнал является относительным и может значительно различаться между разными сканерами, производителями, пациентами и т.д. Нормализация помогает уменьшить этот эффект, делая признаки более сопоставимыми и воспроизводимыми.

Изображения были приведены к единому размеру воксела с использованием команды `resampledPixelSpacing: [3, 3, 3]`. Это означает, что размер каждого воксела был изменен до 3×3×3 мм. Данный этап обработки стандартизирует пространственное разрешение изображений, что важно для обеспечения стабильности и воспроизводимости радиомических признаков, особенно при работе с данными, полученными с разной толщиной среза (например, 3–7 мм, как в нашем исследовании). Использовался `interpolator: 'sitkBSpline'`.

Параметр `binWidth: 5` указывает на то, что сигналы пикселей были дискретизированы с шириной бина 5. Это процесс, который уменьшает количество уникальных значений сигнала в изображении, делая текстурные признаки более стабильными и менее чувствительными к шуму [7].

В дополнение к исходным изображениям (Original), были применены фильтры LoG с сигмами 3.0 и 5.0, а также Wavelet. Эти фильтры используются для выделения различных текстурных паттернов и деталей на изображении.

После этих шагов предварительной обработки были извлечены радиомические признаки следующих классов: `shape`, `firstorder`, `glcm`, `gldm`, `glszm`, `gldm`.

Образования были разделены для бинарной задачи классификации: класс 0 (41 пациент) — муцинозные образования (ВПМН, ВПМН-карциномы, муцинозные цистаденомы, цистаденокарциномы), класс 1 (26 пациентов) — немучинозные образования (серозные цистаденомы, постнекротические кисты). Для оценки всех моделей использовались такие метрики, как ROC-AUC, PR-AUC, точность, чувствительность, специфичность, F1-score.

Качество проведённого радиомического исследования дополнительно оценивалось с использованием шкалы RQS 2.0 (Radiomics Quality Score) [8], которая включает критерии, отражающие полноту методологического описания, корректность обработки данных, наличие валидации, анализ клинической полезности и экономической целесообразности. Применение RQS позволило системно оценить сильные и слабые стороны исследования

(например, объём выборки, наличие независимой валидации, степень стандартизации протоколов визуализации и обработки данных), а также обозначить направления для последующей оптимизации дизайна будущих работ.

Выбор предикторов

Предикторы представляют собой количественные радиомические признаки, извлеченные из МРТ-изображений кистозных образований поджелудочной железы.

Предварительный отбор признаков включал удаление признаков с нулевой дисперсией (константных) и нечисловых столбцов.

Для интерпретации вклада отдельных радиомических признаков в формирование предсказаний модели был проведён анализ SHAP (SHapley Additive exPlanations). Данный подход позволяет количественно оценить влияние каждого признака на итоговое решение алгоритма машинного обучения, обеспечивая интерпретируемость модели. SHAP-анализ выполнялся после окончательного отбора признаков и обучения моделей, что позволило определить наиболее значимые параметры, оказывающие влияние на классификацию кистозных новообразований.

Разработка модели

Расчет размера выборки для разработки и оценки модели не производился до начала эксперимента. Достаточность размера выборки оценивалась эмпирически через производительность модели на кросс-валидации и стабильность метрик. Использованный набор данных содержит 67 пациентов, что достаточно для начальной разработки модели, но может потребовать увеличения для достижения большей обобщаемости.

Для построения модели были рассмотрены различные типы классификаторов: `RandomForestClassifier (RF)`, `SVM (Support Vector Machine)`, `XGBClassifier (XGB)`, `LogisticRegression (LR)`, `LGBMClassifier (LGBM)`, `AutoML_FLAML`, `StackingClassifier`. Обоснованием выбора этих моделей является их широкое применение в задачах диагностики, способность обрабатывать сложные зависимости и обеспечивать высокую производительность. Дополнительно был реализован ансамблевый подход, который объединяет прогнозы отдельных моделей для потенциального улучшения общей производительности.

AutoML-подход использовался для автоматизированного подбора модели и её гиперпараметров без ручного вмешательства. Для AutoML была задана фиксированная конфигурация, включавшая ограничения по времени выполнения, перечень допустимых моделей, а также критерий оптими-

зации — ROC-AUC. Алгоритм автоматически выполнял поиск по пространству моделей и гиперпараметров, выбирая комбинации, обеспечивающие наилучшее качество классификации в рамках заданных ограничений.

Гиперпараметры других моделей (например, `n_estimators`, `max_depth`, `learning_rate`, `class_weight` и др.) были заданы на этапе подготовки анализа и фиксированы в рабочем коде, что обеспечивало воспроизводимость результатов и предотвращало влияние неконтролируемого подбора параметров на итоговую оценку качества классификации.

Внутренняя валидация осуществлялась с помощью 5-кратной кросс-валидации, что обеспечивает надежную оценку производительности модели.

Для оценки модели использовались следующие метрики: ROC-AUC, PR AUC, точность, чувствительность, специфичность, F1-score. Сравнение моделей производилось на основе всех этих метрик, наилучшая модель была определена по результатам ROC-AUC.

Для визуализации результатов были построены ROC-кривые. Дообучение модели на основе результатов оценки в нашем исследовании не проводилось. Эффективность моделей рассчитывалась после тестирования обученных моделей на тестовых данных в каждой группе кросс-валидации.

Различия между данными для разработки и валидации в нашем исследовании минимальны, поскольку для внутренней валидации использовались те же данные, разделенные на тренировочные и тестовые группы в рамках кросс-валидации. Все объекты принадлежат к одной когорте, критерии включения и исключения, а также методы измерения предикторов были идентичными для всех данных.

Результаты

Оценки производительности моделей представлены в табл. 1. Для каждой модели указаны ROC-AUC, PR AUC, точность, чувствительность, специфичность, F1-score. Эти метрики отражают среднюю производительность по 5 группам кросс-валидации.

Анализ полученных результатов (табл. 1, рис. 2) показал, что среди используемых моделей машинного обучения наибольшие значения метрик продемонстрировал алгоритм Random Forest. Он обеспечил максимальные значения ROC-AUC (0,828) и PR-AUC (0,754), что свидетельствует о его наилучшей способности различать классы кистозных опухолей поджелудочной железы. Кроме того, модель продемонстрировала наибольшую специфичность (0,951), что указывает на высокую способность корректно классифицировать немущинозные образования. Однако чувствительность данного алгорит-

ма оказалась относительно невысокой (0,346), что может говорить о склонности модели к пропуску части муцинозных КОПЖ при акценте на правильное распознавание немущинозных.

Близкие результаты по общему качеству классификации показала модель LightGBM, продемонстрировавшая ROC-AUC = 0,771 и PR-AUC = 0,681 при более сбалансированных показателях чувствительности (0,538) и специфичности (0,805). Это делает её потенциально более универсальным инструментом для клинического применения.

Модель XGBoost показала несколько хуже результаты по сравнению с LightGBM (ROC-AUC = 0,738, PR-AUC = 0,634), но сохранила удовлетворительный баланс между чувствительностью и специфичностью, что также подтверждает её пригодность для подобных задач.

Модели AutoML_Stacking и логистическая регрессия продемонстрировали идентичные значения чувствительности и точности (0,538), при этом ROC-AUC составил 0,683 и 0,676 соответственно, что позволяет рассматривать их как сопоставимые по эффективности модели среднего уровня. SVM показала хорошие значения специфичности (0,976), однако чувствительность оказалась нулевой, что свидетельствует о неспособности данной модели корректно идентифицировать случаи муцинозных КОПЖ в имеющихся данных. Модель FLAML, напротив, характеризовалась умеренной точностью (0,627) и достаточно высокой специфичностью (0,805), но низким уровнем чувствительности (0,346), что также ограничивает её практическую применимость.

Таким образом, результаты сравнительного анализа указывают, что среди всех рассмотренных моделей наилучшие диагностические характеристики продемонстрировал алгоритм Random Forest, обеспечивший наиболее высокую площадь под ROC-кривой и наилучшее соотношение специфичности и общей точности классификации.

В рамках анализа были получены усреднённые абсолютные значения SHAP (mean SHAP value), отражающие средний вклад каждого признака в изменение вероятности принадлежности к тому или иному классу. Графическое представление результатов продемонстрировало, что ведущими предикторами оказались текстурные и признаки высшего порядка после применения фильтров wavelet.

Представленный на рис. 3 график отражает средние абсолютные значения SHAP для 20 наиболее значимых радиомических признаков, то есть их средний вклад в изменение предсказаний модели в задаче бинарной классификации кистозных образований поджелудочной железы. Наибольшее влияние на результат оказывает признак `adc_wavelet-HL`

Таблица 1. Сравнительная оценка эффективности моделей машинного обучения. В таблице представлены значения ROC-AUC, PR-AUC, точности, чувствительности, специфичность, F1-score моделей машинного обучения (AutoML, SVM, FLAML, LogisticRegression, Random Forest, XGBoost, LightGBM)

Table 1. ROC-AUC, PR-AUC, accuracy, sensitivity, specificity, and F1-score for the models: AutoML, SVM, FLAML, Logistic Regression, Random Forest, XGBoost, and LightGBM

Модель	Точность	Чувствительность	Специфичность	F1-score	ROC-AUC	PR-AUC
AutoML_Stacking	0,64	0,54	0,71	0,54	0,68	0,57
AutoML_FLAML	0,63	0,35	0,80	0,42	0,52	0,47
RF	0,72	0,35	0,95	0,49	0,83	0,75
SVM	0,60	0,00	0,98	0,00	0,62	0,46
XGB	0,70	0,46	0,85	0,55	0,74	0,63
LR	0,64	0,54	0,71	0,54	0,68	0,57
LGBM	0,70	0,54	0,80	0,58	0,77	0,68

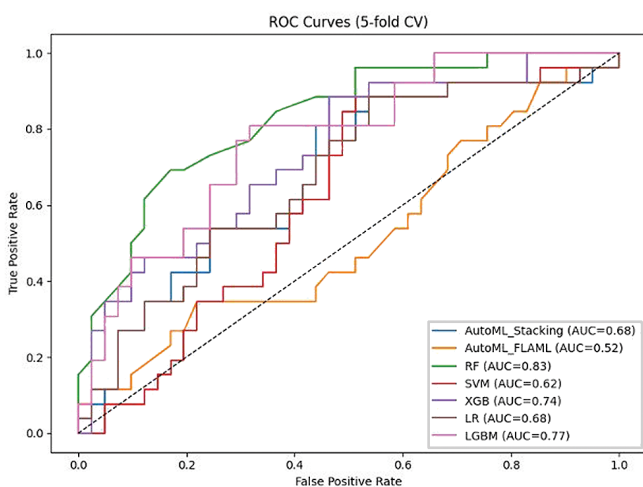


Рис. 2. ROC-кривые разработанных моделей машинного обучения

Fig. 2. ROC curves of the machine-learning models

HlglrlmLongRunLowGrayLevelEmphasis, связанный с текстурными характеристиками диффузионно-взвешенного изображения с карт ADC. Значимый вклад также вносят признаки первого порядка из T₁-взвешенных изображений после вейвлет-преобразования (t1_wavelet-LHLfirstorderMinimum, t1_wavelet-LLHfirstorderMean, t1_wavelet-HHLfirstorderMedian), а также лог-сигма и текстурные GLCM-признаки T₂-ВИ и ДВИ.

Характер распределения важности показывает, что модель опирается на сочетание признаков из разных последовательностей (T₁-ВИ, T₂-ВИ, ДВИ, карты ADC) и различных классов (first-order, GLCM, GLRLM, GLSZM, shape), однако лидирующие позиции занимают текстурные признаки, отражающие неоднородность, размер и распределение зон с различной интенсивностью сигнала.

Таким образом, включение SHAP-анализа позволило не только определить ключевые признаки,


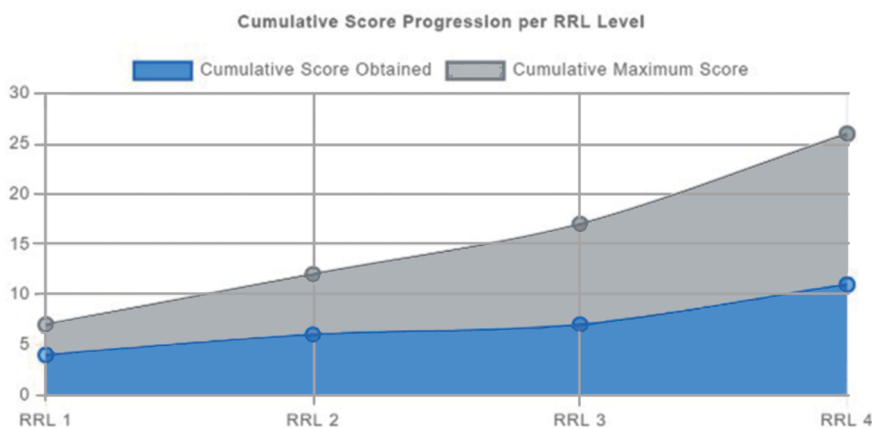


Рис. 3. Диаграмма значимости радиомических признаков по среднему абсолютному значению SHAP

Fig. 3. Diagram of radiomic feature importance based on mean absolute SHAP values



влияющие на итоговую классификацию, но и повысить интерпретируемость полученной модели.

При оценке результатов по RQS 2.0 наша модель соответствует стандарту RRL на 42 % (11 баллов из 26). В контексте RQS 2.0 [8] под RRL понимают Radiomics Readiness Levels — уровни «готовности» радиомического исследования к клиническому внедрению, по аналогии с Technology Readiness Levels. Каждый последующий уровень RRL отражает шаг вперёд от ранних экспериментальных работ к моделям, близким к практическому использованию, с увеличением требований к дизайну, валидации и отчётности.

На рис. 4 график отражает динамику суммарного балла по шкале RQS (Radiomics Quality Score) по уровням RRL: от RRL 1 до RRL 4 кумулятивный полученный балл возрастает с 4 до 11, тогда как максимальный теоретически возможный балл на этих этапах увеличивается с 7 до 26. Видно, что с переходом от RRL 1 к RRL 4 суммарный набранный балл возрастает, однако остаётся ниже теоретического максимума, что указывает на выполненное большинство ключевых требований RQS при сохранении потенциала для дальнейшего методологического усовершенствования исследования.

Обсуждение

Опубликованные к настоящему времени исследования по радиомике кист поджелудочной железы остаются немногочисленными. Так в работе Ştefan et al [5] радиомический анализ МРТ-изображений использовали для дифференциальной диагностики муцинозных и немучинозных кистозных новообразований: авторы выполняли сегментацию кист, извлекали радиомические признаки с T_2 -взвешенных изображений и ADC-карт и далее проводили статистический анализ, показав, что текстурные и другие радиомические характеристики на основе T_2 и ADC позволяют успешно дифференцировать муцинозные и немучинозные поражения (с чувствитель-

Рис. 4. График набранных баллов по шкале Radiomics Quality Score 2.0 на различных уровнях Radiomics Readiness Level (RRL). Синим цветом на графике обозначен кумулятивный набранный балл по шкале RQS для нашего исследования, серым — соответствующее ему максимально возможное кумулятивное значение для каждого уровня RRL

Fig. 4. Cumulative Radiomics Quality Score 2.0 points across different Radiomics Readiness Levels (RRL). The blue line represents the cumulative RQS score in our study, while the gray line indicates the maximum possible cumulative score for each RRL level

ностью 83,2–100 % и специфичностью 69,3–96,2 % для T_2 , чувствительностью 40–85 % и специфичностью 60–96,7 % для ADC). При этом авторы измеряли интенсивность МРТ-сигнала кистозных образований, что не позволило дифференцировать кистозные новообразования ПЖ, в отличие от радиомического анализа.

В исследовании Yao et al [6] была предложена более сложная, полностью автоматизированная система поддержки принятия решений для ВПМН, включающая автоматическую сегментацию поджелудочной железы нейросетью nnUNet, последующее использование моделей глубокого обучения (CNN или трансформера) и комбинированной радиомической модели XGBoost, дополненной клиническим признаком, для многоклассовой классификации по степени риска (нет риска, низкий риск, высокий риск); интеграция радиомики и клинических данных позволила получить ROC-AUC = 0,893, что существенно превзошло архитектуру AlexNet, разработанную без радиомических признаков (ROC-AUC = 0,648).

Наша модель машинного обучения продемонстрировала сопоставимые с опубликованными работами диагностические показатели при бинарной классификации кистозных образований поджелудочной железы на потенциально злокачественные и доброкачественные образования, что подтверждает высокую информативность радиомических признаков многопараметрической МРТ.

К ограничениям данного исследования можно отнести отсутствие внешней валидации. Хотя была использована кросс-валидация для внутренней оценки, внешняя валидация на независимом наборе данных была бы полезна для подтверждения производительности модели. Пропущенные данные были обработаны методом замены медианой, что является простым, но не всегда оптимальным решением. Потенциальное переобучение было снижено за счет использования кросс-валидации и на-

стройки гиперпараметров, но полностью исключить его сложно.

Таким образом перспективным направлением является расширение выборки и валидация модели в многоцентровых исследованиях, что может повысить устойчивость и обобщающую способность алгоритма. Дополнительное направление — включение клинических и лабораторных данных, а также использование гибридных подходов, сочетающих классическое машинное обучение и глубокие нейросетевые архитектуры.

Выводы

Проведённое исследование показало, что радиомический анализ многопараметрической МРТ в сочетании с алгоритмами машинного обучения, прежде всего Random Forest и LightGBM, может быть использован для дифференциальной диагностики доброкачественных и потенциально злокачественных кистозных новообразований поджелудочной железы. Качество радиомического исследования было оценено с использованием шкалы RQS 2.0, что повышает прозрачность и методологическую обоснованность работы. Полученные результаты были интерпретированы с использованием SHAP-анализа, и указывают на перспективность радиомики как инструмента объективной стратификации риска. Дальнейшее расширение выборки, внешняя валидация и интеграция клинических данных рассматриваются как необходимые шаги для повышения обобщаемости и потенциальной клинической применимости разработанной модели.

Вклад авторов

С.С. Карпов: обзор публикаций по теме статьи, разработка дизайна исследования, сбор данных, написание текста рукописи.

Е.В. Кондратьев: разработка дизайна исследования, сбор данных.

А.А. Усталов: статистическая обработка.

С.А. Шмелева: А.А.: сбор данных.

В.М. Тарнопольский: сбор данных.

Финансирование. Исследование проведено без спонсорской поддержки.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Соответствие принципам этики. Одобрено локальным этическим комитетом.

Информированное согласие. Не требовалось подписания информированного согласия на публикацию данных.

Поступила: 26.01.2026.

Принята к публикации: 10.02.2026.

Опубликована online: 26.03.2026.

Список литературы / References

1. Скульский СК, Ратников ВА, Лубашев ЯА, и др. Магнитно-резонансная томография в лучевой диагностике кистозных неоплазий поджелудочной железы на этапах медицинского обследования. *Врач.* 2022;33(11):40-47.
Skulskiy SK, Ratnikov VA, Lubashev YA, et al. MRI diagnosis pancreatic cystics neoplasms at the stages of a medical examination. *Vrach.* 2022;33(11):40-47. (In Russ.) <https://doi.org/10.29296/25877305-2022-11-07>
2. Ardeshtna DR, Cao T, Rodgers B, et al. Recent advances in the diagnostic evaluation of pancreatic cystic lesions. *World J Gastroenterol.* 2022;28(6):624-34. <https://doi.org/10.3748/wjg.v28.i6.624>
3. Rogowska J, Semeradt J, Durko Ł, Mafecka-Wojcieszko E. Diagnostics and Management of Pancreatic Cystic Lesions-New Techniques and Guidelines. *J Clin Med.* 2024 Aug 8;13(16):4644. <https://doi.org/10.3390/jcm13164644>
4. Кондратьев ЕВ, Шмелева СА, Усталов АА и др. Теоретические основы текстурного анализа КТ-изображений образований органов брюшной полости: обзор. *Лучевая диагностика и терапия.* 2025;16(1):33-46.
Kondratyev EV, Shmeleva SA, Ustalov AA, et al. Theoretical basics of abdominal CT radiomics: a review. *Diagnostic Radiology and Radiotherapy.* 2025;16(1):33-46. (In Russ.). <https://doi.org/10.22328/2079-5343-2025-16-1-33-46>
5. Ștefan PA, Lupean RA, Lebovici A, et al. Quantitative MRI of Pancreatic Cystic Lesions: A New Diagnostic Approach. *Healthcare (Basel).* 2022;10(6):1039. <https://doi.org/10.3390/healthcare10061039>
6. Yao L, Zhang Z, Demir U, et al. Radiomics Boosts Deep Learning Model for IPMN Classification. *Mach Learn Med Imaging.* 2023;14349:134-143. https://doi.org/10.1007/978-3-031-45676-3_14
7. Zwanenburg A, Vallières M, Abdalah MA, et al. The Image Biomarker Standardization Initiative: Standardized Quantitative Radiomics for High-Throughput Image-based Phenotyping. *Radiology.* 2020;295(2):328-338. <https://doi.org/10.1148/radiol.2020191145>
8. Lambin P, Woodruff HC, Mali SA, et al. Radiomics Quality Score 2.0: towards radiomics readiness levels and clinical translation for personalized medicine. *Nat Rev Clin Oncol.* 2025;22(11):831-846. <https://doi.org/10.1038/s41571-025-01067-1>

Information about the authors

S.S. Karpov, <https://orcid.org/0000-0002-0163-8335>.

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

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

S.A. Shmeleva, <https://orcid.org/0009-0007-5724-2763>.

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

Authors' contributions

S.S. Karpov: review of publications, study design development, data collection, writing the text of the manuscript.

E.V. Kondratyev: study design development, data collection.

A.A. Ustalov: statistical procession.

S.A. Shmeleva: data collection.

V.M. Tarnopolsky: data collection.

Funding. The study had no sponsorship.

Conflict of interests. Not declared.

Ethical compliance. Approved by the local ethics committee.

Informed consent. Not required.

Received: 26.01.2026.

Accepted for publication: 10.02.2026.

Published online: 26.03.2026.