

Оценка возможностей машинного обучения в радиомике для прогнозирования риска развития клинически значимых панкреатических фистул после панкреатодуоденальных резекций на КТ-изображениях

© Кондратьев Е.В.¹, Мазурок А.В.^{1*}, Усталов А.А.¹, Шмелева С.А.¹,
Стручков В.Ю.¹, Марков П.В.¹, Сеницын В.Е.²

¹ ФГБУ “Национальный медицинский исследовательский центр хирургии им. А.В. Вишневского” Минздрава России; 117997 Москва, ул. Большая Серпуховская, д. 27, Российская Федерация

² ФГБОУ ВО “Московский государственный университет имени М.В. Ломоносова”; 119991 Москва, Ленинские горы, д. 1, Российская Федерация

Несмотря на снижение летальности при панкреатодуоденальных резекциях (ПДР), частота послеоперационных осложнений остается высокой (20–60%). Одним из наиболее грозных осложнений является послеоперационная панкреатическая фистула. Прогнозирование рисков развития осложненного послеоперационного периода остается актуальной проблемой. Одним из ключевых факторов риска признана структура поджелудочной железы, при этом современные подходы в предсказании возникновения клинически значимого панкреатического свища интегрируют не только морфологические, но и радиомические параметры КТ-изображений с использованием методов искусственного интеллекта.

Цель исследования: оценка возможностей машинного обучения в радиомике для прогнозирования клинически значимых панкреатических фистул после ПДР и разработка системы поддержки врачебных решений на базе платформы “Виртуальная биопсия”.

Материал и методы. Ретроспективно проанализированы данные 117 пациентов, перенесших ПДР (2016–2019 гг.) в НМИЦ хирургии им. А.В. Вишневского. Методами машинного обучения исследованы текстурные показатели предоперационных компьютерных томограмм.

Результаты. У 31 (26,5%) пациента зафиксированы клинически значимые панкреатические фистулы. Возрастных различий между группами с осложнениями и без них не выявлено ($p < 0,022$). У 11 (9,4%) пациентов диагностирован клинически значимый свищ, у 20 (17,1%) – его сочетание с аррозивным кровотечением. Пик фистул отмечен на 4–6-е сутки, кровотечений – на 8–14-е сутки. Радиомическая модель AdaBoost показала наивысшую эффективность (ROC AUC = 0,815), превзойдя альтернативные подходы: Gradient Boosting (0,631), XGBoost (0,677), LightGBM (0,631) и Stacking (0,662). Интеграция морфологических признаков не улучшила прогностическую способность, вероятно, из-за зашумления данных. Модели на основе семантических параметров (макс. ROC AUC = 0,653) подтвердили ограниченную клиническую применимость.

Заключение. Методы машинного обучения эффективны в прогнозировании клинически значимых панкреатических фистул после панкреатодуоденальных резекций. Данные радиомического анализа позволяют расширить диагностические возможности методики КТ, показывая превосходство в метриках точности моделей над классическими семантическими в отдельности.

Ключевые слова: радиомика; текстурный анализ; поджелудочная железа; панкреатодуоденальная резекция; машинное обучение; панкреатический свищ


Авторы подтверждают отсутствие конфликтов интересов.

Для цитирования: Кондратьев Е.В., Мазурок А.В., Усталов А.А., Шмелева С.А., Стручков В.Ю., Марков П.В., Сеницын В.Е. Оценка возможностей машинного обучения в радиомике для прогнозирования риска развития клинически значимых панкреатических фистул после панкреатодуоденальных резекций на КТ-изображениях. *Медицинская визуализация*. 2025; 29 (4): 81–93. <https://doi.org/10.24835/1607-0763-1579>

Поступила в редакцию: 18.06.2025.

Принята к печати: 27.06.2025.

Опубликована online: 31.10.2025.



Assessment of machine learning in radiomics for predicting the risk of clinically significant pancreatic fistulas after pancreatoduodenal resections using CT imaging

© Evgeny V. Kondratyev¹, Alina V. Mazurok^{1*}, Andrey A. Ustalov¹, Sofia A. Shmeleva¹, Vladimir Y. Struchkov¹, Pavel V. Markov¹, Valentin E. Sinitsyn²

¹ A.V. Vishnevsky National Medical Research Center of Surgery of the Ministry of Healthcare of the Russian Federation; 27, Bol'shaya Serpukhovskaya str., Moscow 117997, Russian Federation

² Lomonosov Moscow State University; GSP-1, Leninskie Gory, Moscow 119991, Russian Federation

Despite the reduction in mortality after pancreatoduodenal resections, the incidence of postoperative complications remains high (20–60%). One of the most severe complications is postoperative pancreatic fistula. Predicting the risks of a complicated postoperative period remains an urgent problem. One of the key risk factors is the pancreatic structure, and modern approaches to predicting clinically relevant pancreatic fistula integrate not only morphological but also radiomic parameters of CT images using artificial intelligence methods.

Aim. To evaluate the potential of machine learning in radiomics for predicting clinically relevant pancreatic fistulas after pancreatoduodenal resection and to develop a clinical decision support system based on the “Virtual Biopsy” platform.

Methods. Retrospective analysis of data from 117 patients who underwent pancreatoduodenal resection (2016–2019) at the A.V. Vishnevsky National Medical Research Center of Surgery. Machine learning methods were applied to assess textural features of preoperative CT scans.

Results. Clinically relevant pancreatic fistulas were recorded in 31 patients (26.5%). Clinically significant fistula alone was diagnosed in 11 patients (9.4%), while its combination with erosive bleeding was observed in 20 patients (17.1%). The peak incidence of fistulas occurred on days 4–6, and of bleeding on days 8–14. The radiomic AdaBoost model demonstrated the highest efficacy (ROC AUC = 0.815), outperforming alternative approaches: Gradient Boosting (0.631), XGBoost (0.677), LightGBM (0.631), and Stacking (0.662). Integration of morphological features did not improve predictive capability, likely due to data noise. Models based on semantic parameters (max. ROC AUC = 0.653) confirmed limited clinical applicability.

Conclusion. Machine learning methods are effective in predicting clinically relevant pancreatic fistulas after pancreatoduodenal resections. Radiomic analysis extends the diagnostic potential of CT, demonstrating superior model accuracy metrics compared to classical semantic features alone.

Keywords: machine learning; image processing, computer-assisted; pancreatic fistula; pancreaticoduodenectomy; tomography, X-ray computed

Conflict of interest. The authors declare no conflict of interest. The study had no sponsorship.

For citation: Kondratyev E.V., Mazurok A.V., Ustalov A.A., Shmeleva S.A., Struchkov V.Y., Markov P.V., Sinitsyn V.E. Assessment of machine learning in radiomics for predicting the risk of clinically significant pancreatic fistulas after pancreatoduodenal resections using CT imaging. *Medical Visualization*. 2025; 29 (4): 81–93. <https://doi.org/10.24835/1607-0763-1579>

Received: 18.06.2025.


Accepted for publication: 27.06.2025.

Published online: 31.10.2025.

Введение

Развитие хирургической панкреатологии в последние десятилетия демонстрирует положительную динамику – снижение риска неблагоприятных исходов резекции поджелудочной железы, в том числе послеоперационных осложнений. В последние 20 лет летальность после панкреатодуоденальной резекции (ПДР) составляет 2–5% [1], тогда как в 90-х годах XX века этот показатель достигал 16–25% [2–4]. В высокоспециализированных

хирургических центрах показатель летальности в настоящее время находится на уровне 1–1,5% [5]. Текущие тенденции показывают, что, несмотря на снижение послеоперационной летальности, частота осложнений остается высокой – 30–50% при ПДР и 22–50% при дистальных резекциях [6]. Наиболее серьезными специфическими осложнениями после ПДР являются послеоперационная панкреатическая фистула и кровотечение, традиционно ассоциирующиеся с высокой летальностью и длительной госпитализацией [7].



Несмотря на прогресс в хирургической панкреатологии, вопросы, связанные с прогнозированием и управлением рисками послеоперационных осложнений, остаются нерешенной проблемой.

Согласно классификации Международной группы по изучению панкреатических свищей (ISGPS), послеоперационная панкреатическая фистула (ПОПФ) диагностируется при наличии панкреатогенного отделяемого с уровнем амилазы, превышающим ее содержание в сыворотке крови в 3 раза на 3-и и более сутки после операции [8]. В 2005 г. было выделено три типа свищей: Grade A (бессимптомный), Grade B (осложнения без необходимости хирургического вмешательства) и Grade C (тяжелые осложнения, требующие хирургической коррекции) [9]. После пересмотра классификации в 2016 г. Grade A была переименована в “биохимическую несостоятельность”, а клинически значимыми свищами остались Grade B и C [10].

Факторами риска послеоперационных осложнений после ПДР являются возраст пациента [11], сердечно-сосудистые заболевания [12] и/или сахарный диабет в анамнезе [13], гендерная принадлежность [13], длительность оперативного вмешательства. В числе факторов риска послеоперационных осложнений, в том числе панкреатической фистулы, определены и характеристики поджелудочной железы – “мягкая” структура (консистенция паренхимы, определяемая хирургом пальпаторно во время операции) и морфологические характеристики железы (толщина, диаметр протока) по данным КТ с контрастным усилением [14–16], степень жировой инфильтрации и фиброза по данным МРТ [17, 18], высокая ферментативная активность железы [19, 20].

Особое внимание уделяется структуре поджелудочной железы, которая является ключевым фактором риска. Дооперационная оценка структуры железы позволяет выделить группы риска и оптимизировать дальнейшие профилактические и лечебные мероприятия.

Исследования различных авторов направлены на оценку структуры поджелудочной железы с использованием КТ как без контрастного препарата [21–23], так и с его применением, анализируя распределение контрастного препарата в паренхиме [24].

Некоторые исследователи предлагают использовать данные МРТ для оценки жировой инфильтрации, фиброза и прогнозирования риска осложнений [17, 18].

Многие авторы отмечают, что “мягкая” структура железы является ключевым фактором риска послеоперационных осложнений, способствуя


развитию панкреатической фистулы и связанных с ней других осложнений. Высокая ферментативная активность, обусловленная большим количеством сохранных ацинусов, способствует развитию частичной несостоятельности панкреатикоеюноанастомоза с последующим парапанкреатическим распространением секрета поджелудочной железы [19, 20].

Ранее в НМИЦ хирургии им. А.В. Вишневского нами было проведено исследование, оценивающее роль КТ с контрастным усилением в прогнозировании панкреатических свищей после резекций поджелудочной железы. В ходе исследования были выявлены значимые факторы риска: толщина железы $> 17,5$ мм, диаметр протока $< 3,25$ мм, плотность $< 39,5$ HU, а также коэффициенты накопления (КН) контраста в различных фазах. Например, $КН_{вен.} < 0,7$ связан с панкреатитом, а $КН_{выд.} > 0,54$ указывает на риск развития свищей. Эти параметры позволяют выделить пациентов с повышенным риском осложнений, что подчеркивает важность предоперационной КТ с контрастированием для улучшения прогнозирования [14–16].

Современная медицина требует разработки новых диагностических подходов для прогнозирования послеоперационных осложнений на дооперационном этапе. Одним из перспективных направлений является радиомика – метод анализа медицинских изображений, основанный на извлечении и интерпретации радиомических признаков, таких как текстурные, объемные и геометрические характеристики. Эти признаки отражают распределение значений пикселей или вокселей в изображении и могут быть использованы для диагностики, прогноза и лечения заболеваний [25].

Интеграция методов искусственного интеллекта, в частности машинного обучения, позволяет значительно повысить точность и воспроизводимость радиомического анализа [26]. Самостоятельно разрабатывая алгоритм для обработки предоставленных данных, система непрерывно обучается, опираясь на предыдущий опыт, тем самым увеличивая точность алгоритма. С помощью методов машинного обучения появляется возможность анализа большого объема данных и выявления связей между показателями. Текстурные показатели могут использоваться для построения радиомических моделей с помощью методики машинного обучения, делая радиомику еще более перспективной областью развития медицины.

Традиционные подходы к прогнозированию осложнений, таких как панкреатическая фистула, часто основываются на семантических признаках, извлекаемых из КТ и МРТ. Семантические признаки – это визуальные характеристики, определяемые



рентгенологами, такие как размер панкреатического протока, объем поджелудочной железы и др. Однако эти методы ограничены субъективностью, низкой воспроизводимостью и умеренной надежностью. Радиомика, напротив, позволяет количественно анализировать сложные визуальные паттерны, выявляя параметры, недоступные для визуальной оценки, а также объективно измерять параметры изображения, оцениваемые “глазами рентгенолога”, – подход, который в том числе используется в диагностике онкологических заболеваний [27, 28]. Применение радиомики открывает новые возможности для объективного предоперационного прогнозирования осложнений [29].

Комбинированные модели, использующие как семантические, так и радиомические данные, демонстрируют высокую эффективность [30]. Добавление в модели различной клинической информации также может повышать эффективность моделей. Другой точкой приложения для улучшения получаемых результатов является методика обработки радиомических показателей – в последнее время появляются отечественные исследования, подтверждающие перспективность применения машинного обучения для прогнозирования осложнений после ПДР и выявления ключевых факторов риска [31].

Цель исследования: разработка модели прогнозирования послеоперационных осложнений для системы поддержки врачебных решений на основе радиомики и искусственного интеллекта в рамках разработанной платформы “Виртуальная биопсия”, а также оценка методов машинного обучения для предсказания риска клинически значимых панкреатических фистул у пациентов после ПДР. Модель прогнозирования панкреатической фистулы как инструмент персонализированной медицины позволит точно оценивать индивидуальные риски и обоснованно принимать клинические решения. Внедрение таких моделей в клиническую практику позволило бы улучшить исходы лечения и оптимизировать стратегии, обеспечивая эффективное распределение ресурсов в здравоохранении. Точные прогнозирующие модели способствуют повышению качества медицинской помощи и адаптации лечения к уникальным характеристикам пациентов.

Материал и методы

Общая характеристика пациентов

В ретроспективное исследование было включено 117 пациентов. Средний возраст пациентов составил 66,2 года (диапазон: 46–83), из них 63 (53,8%) мужчины и 54 (46,2%) женщины. Все они прошли хирургическое лечение в объеме ПДР в

абдоминальном отделении НМИЦ хирургии им. А.В. Вишневского за период 2016–2019 гг.

Критерии включения:

- история выполненного оперативного вмешательства на поджелудочной железе в объеме ПДР;
- наличие у пациентов дооперационных данных КТ-исследования с контрастным усилением, наличием результатов всех четырех фаз сканирования (нативной, артериальной, венозной, отсроченной);
- все исследования должны быть удовлетворительного качества. Толщина среза в диапазоне от 1 до 5 мм.

Критерии исключения:

- неполные данные дооперационной КТ с отсутствием данных об одной и более фаз сканирования;
- неудовлетворительное качество изображений и невозможность их оценки;
- невозможность сегментации паренхимы дистального отдела поджелудочной железы из-за выраженной атрофии паренхимы и дилатации панкреатического протока;
- история локорегионарного лечения до выполнения предоперационного КТ-исследования.

В данное исследование были включены пациенты с компьютерными томограммами, выполненными с использованием различных протоколов сканирования, так как пациенты поступали из различных медицинских учреждений. Изображения были получены с использованием различных компьютерных томографов, что также привело к вариациям в протоколах сканирования.

Не был учтен эффект временных различий между моментом выполнения сканирования и достижением контрастности в исследуемых структурах.


Использовались различные контрастные средства, которые отличались по осмолярности и объему (неионные мономерные рентгеноконтрастные вещества), а также варьировалась скорость введения контрастного препарата.

Текстурный анализ КТ-изображений

Радиомический анализ производился с помощью ПО Slicer 5.2 [32] и модуля Pyradiomics [33].

Типы изображений, использованные для радиомического анализа:

1. Original – исходное изображение без применения фильтров.
2. LoG (Laplacian of Gaussian) – фильтр Лапласиана Гаусса с разными значениями sigma (1.0, 2.0, 3.0, 4.0, 5.0), который выделяет границы и текстуры на различных масштабах.



3. Wavelet – вейвлет-преобразование, позволяющее анализировать изображение на разных уровнях детализации.

4. Square, SquareRoot, Logarithm, Exponential, Gradient – фильтры, применяющие математические операции к интенсивности пикселей для выделения различных характеристик.

Классы признаков, извлеченных из изображений:

1. Shape – геометрические параметры, описывающие форму области интереса (например, объем, площадь поверхности, компактность).

2. Firstorder – статистические параметры первого порядка, такие как среднее значение, дисперсия, асимметрия и эксцесс интенсивности пикселей.

3. GLCM (Gray Level Co-occurrence Matrix) – признаки, основанные на матрице совстречаемости уровней серого, описывающие текстуру (например, контраст, корреляция, энтропия).

4. GLRLM (Gray Level Run Length Matrix) – признаки, основанные на длине серий уровней серого, характеризующие текстуру через последовательности пикселей с одинаковой интенсивностью.

5. GLSZM (Gray Level Size Zone Matrix) – признаки, основанные на зонах уровней серого, описывающие текстуру через размеры областей с одинаковой интенсивностью.

6. GLDM (Gray Level Dependence Matrix) – признаки, основанные на зависимости уровней серого, характеризующие текстуру через взаимосвязь между пикселями.

NGTDM (Neighboring Gray Tone Difference Matrix) – признаки, основанные на разнице уровней серого между соседними пикселями.

Параметры обработки изображений:

Нормализация (normalize) – отключена по умолчанию, так как значения КТ (в единицах Хаунсфилда, HU) уже являются абсолютными.

Ресемплинг (resampling) – изображение ресемплируется до разрешения [1, 1, 1] мм с использованием метода sitkLinear и параметром padDistance 10 (для анализа изображений LoG с высоким фильтром). Это обеспечивает стандартизацию анализа для изображений с разным разрешением и изотропность вокселей.

Ресегментация – выполнена в диапазоне значений –200–500 HU.

Дискретизация изображения (image discretization) – интенсивность пикселей квантуется в бины с шириной 25 HU, что сокращает количество уникальных значений и упрощает анализ текстуры.

Сдвиг массива вокселей (voxelArrayShift) – значения интенсивности сдвигаются на 200 HU для исключения отрицательных значений при расчете некоторых признаков.

Построение ML-модели и анализ ее производительности

Для построения радиомической модели анализа КТ-данных пациентов были использованы методы машинного обучения, направленные на предсказание развития клинически значимой фистулы в послеоперационном периоде.

Панкреатические свищи были разделены для бинарной задачи классификации: класс 0 – отсутствие клинически значимого панкреатического свища, класс 1 – развитие клинически значимого панкреатического свища типа В или С.

Это преобразование облегчило интерпретацию результатов, поскольку наибольшее клиническое значение представляло выделение панкреатических фистул, которые имели худший прогноз.

При обработке данных признаки с низкой вариативностью были исключены. Такой подход способствовал улучшению качества входных данных, необходимых для создания надежной модели. Для выбора признаков, направленного на уменьшение размерности данных и повышение точности моделей, использовался метод SelectKBest, основанный на F-статистике ANOVA. После удаления нерелевантных характеристик, способных создавать шум и снижать эффективность обучения, было выбрано 25 наиболее значимых признаков. Затем эти признаки были стандартизированы для приведения к единому масштабу. После этапа отбора данные были разделены на обучающую и тестовую выборки в соотношении 80:20 с сохранением пропорций классов (stratify). В нашем исследовании клинически незначимые панкреатические фистулы встречаются чаще, чем клинически значимые (соотношение пациентов 86:31). Для устранения этого дисбаланса был применен метод SMOTE (Synthetic Minority Oversampling Technique), который искусственно увеличил количество примеров миноритарного класса. Этот подход улучшил способность моделей правильно классифицировать редкие классы.

Наилучшая конфигурация модели была определена на основе ROC AUC.

Далее создавались дополнительные ансамблевые модели, такие как Stacking Classifier (с использованием комбинации Random Forest, Gradient Boosting и XGBoost) и AdaBoost Classifier (с базовым классификатором Logistic Regression). Для обучения каждой модели использовалась сбалансированная обучающая выборка.

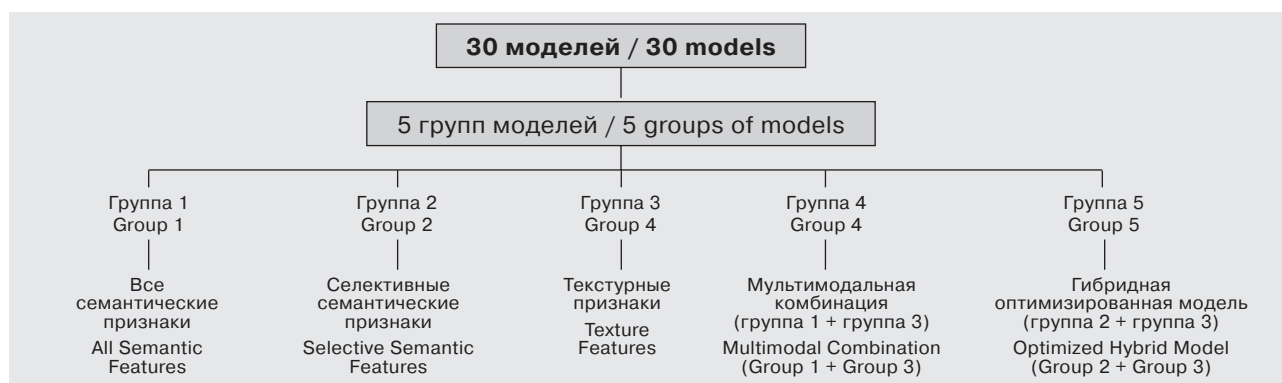



Схема исследования: группы моделей машинного обучения для прогнозирования клинически значимых панкреатических свищей.

Study design: Machine learning model groups for predicting clinically significant pancreatic fistulas.

Для оценки моделей рассчитывались следующие метрики на тестовой выборке:

- **ROC AUC:** Площадь под ROC-кривой
- **PR AUC:** Площадь под PR-кривой
- **Accuracy:** Точность
- **Precision:** Точность предсказания положительного класса
- **Recall (Sensitivity):** Чувствительность
- **F1 Score:** Гармоническое среднее точности и чувствительности
- **Specificity:** Специфичность

После расчета строились матрицы ошибок для наглядной оценки результатов предсказания.

Для визуализации результатов были построены ROC-кривые для всех моделей на тестовой выборке. Для анализа поведения моделей при различных объемах обучающей выборки и последующей оценки их обобщающей способности использовались кривые обучения.

В процессе анализа результатов проводилось сравнение всех моделей с особым вниманием к модели с наивысшими метриками ROC AUC, PR AUC и F1 Score. Оценивалась их применимость для предсказания риска развития клинически значимой панкреатической фистулы после ПДР. В рамках исследования были разработаны модели машинного обучения, по шесть моделей в каждой из пяти групп. Группы формировались на основе различных типов анализируемых признаков.

Группа 1: КТ-морфологические модели (полный набор маркеров)

– Все морфологические параметры, извлеченные из предоперационных КТ-исследований.

Группа 2: КТ-морфологические модели (селективные маркеры)

– Три морфологических признака, ассоциированных с риском развития клинически значимых

ПОПФ в предыдущих исследованиях: диаметр главного панкреатического протока (мм), коэффициент вымывания контрастного агента (НУ, отсроченная/артериальная фаза), аксиальная толщина поджелудочной железы (мм).

Группа 3: радиомические модели (текстурно-топографические признаки)

– Количественные признаки: гистограммные, текстурные (GLCM, GLRLM) и пространственные метрики.

Группа 4: мультимодальная комбинация (КТ-морфология + радиомика)

– Синтез полного морфологического набора (группа 1) с радиомическими данными (группа 3).

Группа 5: оптимизированные гибридные модели (селективные маркеры + радиомика)

– Интеграция ключевых морфологических маркеров (группа 2) с радиомическими паттернами (группа 3).

Цель разработки нескольких групп моделей заключалась в определении оптимального объема данных, который позволит выявить модель с наивысшей производительностью.

Результаты исследования

Послеоперационный период осложнился развитием клинически значимых панкреатических свищей у 31 пациента (26,5% от всей когорты). Статистически значимого различия в возрастных группах пациентов с осложнениями и без развития ПОПФ не выявлено ($p < 0,022$). Среди всех пациентов исследования у 11 (9,4%) был диагностирован изолированный клинически значимый панкреатический свищ типа В и С, тогда как у 20 (17,1%) пациентов наблюдалось сочетание клинически значимого панкреатического свища и аррозивного кровотечения. Клинически значимые панкреатические свищи регистрировались в среднем на





Рис. 1. ROC-кривая комбинированных моделей, анализирующих радиомические и все семантические КТ-признаки, на тестовом dataset.

Fig. 1. ROC curve of combined models analyzing radiomic and all semantic CT features on the test dataset.




Рис. 2. ROC-кривая моделей машинного обучения, анализирующих все семантические КТ-признаки, на тестовом dataset.

Fig. 2. ROC curve of machine learning models analyzing all semantic CT features on the test dataset.

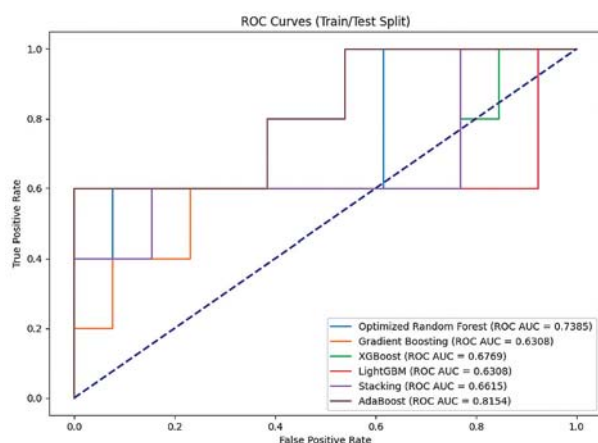


Рис. 3. ROC-кривая моделей машинного обучения, анализирующих радиомические признаки, на тестовом dataset.

Fig. 3. ROC curve of machine learning models analyzing radiomic features on the test dataset.

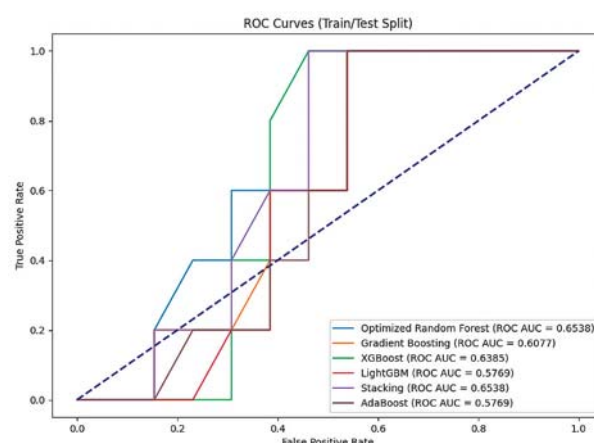


Рис. 4. ROC-кривая моделей машинного обучения, анализирующих селективные семантические КТ-признаки, на тестовом dataset.

Fig. 4. ROC curve of machine learning models analyzing selective semantic CT features on the test dataset.

7,8 ± 6,1 сут, кровотечения – на 9,1 ± 7,8 сут, с пиковыми периодами на 4–6 сут (54,5% свищей) и 8–14 сут (45% кровотечений). Для оптимизации прогнозирования этих осложнений проведен анализ эффективности моделей машинного обучения.

На основе анализа ROC-кривых и значений ROC AUC для пяти групп моделей (рис. 1–5) установлено, что радиомическая модель AdaBoost демонстрирует наивысшую прогностическую эффективность (ROC AUC = 0,815, см. рис. 3),

превосходя как гибридные, так и изолированные морфологические подходы. Интеграция радиомических признаков с тремя селективными морфологическими параметрами (диаметр протока, коэффициент вымывания, толщина железы) не привела к улучшению метрик (см. рис. 5), что может свидетельствовать о зашумлении данных или избыточности признаков. Модели, основанные исключительно на морфологических признаках (см. рис. 2, 4), показывают наименьшую эффективность (максимальный ROC AUC = 0,654), подтвер-

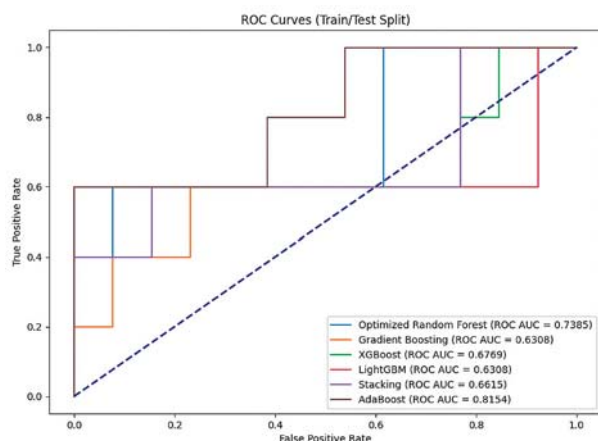



Рис. 5. ROC-кривая моделей машинного обучения, анализирующих радиомические и селективные семантические КТ-признаки, на тестовом dataset.

Fig. 5. ROC curve of machine learning models analyzing radiomic and selective semantic CT features on the test dataset.

ждая важную роль радиомики в прогнозировании клинически значимого свища. Стоит отметить, что семантические модели обладали более слабой прогностической способностью, что объясняется малым количеством оцениваемых параметров, а также высокой субъективностью их получения. Полученные данные подчеркивают важность тщательного отбора признаков и целесообразность использования радиомических моделей в качестве инструмента, обеспечивающего баланс между высокой точностью и устойчивостью к шуму.

Дальнейшие результаты представлены для радиомических моделей, одна из которых продемонстрировала себя наиболее успешно. Метрики их производительности представлены в таблице.

Рассмотрим основные метрики моделей, используемых для предикции клинически значимой

фистулы. Данные результаты включают ROC AUC, PR AUC, точность, чувствительность, специфичность и другие метрики.

AdaBoost демонстрирует наивысшие значения ROC AUC (0,815) и PR AUC (0,772) среди радиомических моделей, а также высокую чувствительность (80%), что указывает на ее способность минимизировать ложноотрицательные прогнозы (см. рис. 3). Однако точность (61,1%) и специфичность (53,8%) остаются относительно низкими, что может быть связано с дисбалансом классов или переобучением. Применение модели AdaBoost обосновано в клинических сценариях, где важна минимизация риска пропуска клинически значимого свища, несмотря на допустимость умеренного уровня ложноположительных результатов.

Optimized Random Forest показывает сбалансированные метрики: ROC AUC 0,738, точность 77,8%, Precision 60%, Recall 60%, F1 60%, специфичность 84,6% (см. таблицу). Эти результаты подчеркивают его устойчивость к шуму и способность сохранять баланс между чувствительностью и специфичностью.

XGBoost и LightGBM демонстрируют низкие значения ROC AUC (0,677 и 0,631 соответственно) и F1-метрику (54,5 и 46,2%, см. таблицу), что делает их менее пригодными для задач, требующих высокой точности и воспроизводимости. Gradient Boosting и Stacking уступают лидерам по ключевым показателям (ROC AUC 0,631 и 0,662 соответственно), несмотря на умеренную специфичность (61,5 и 69,2%, см. таблицу).

Общий вывод

AdaBoost демонстрирует наивысшие ROC AUC (0,815) и чувствительность (80%), обеспечивая раннее выявление клинически значимого свища (см. рис. 3). Несмотря на умеренные точность (61,1%) и специфичность (53,8%), требующие оптимизации, модель сохраняет актуальность

Таблица. Основные метрики моделей, используемых для предикции клинически значимой фистулы в рамках радиомической модели (группа 3)

Table. Key metrics of the models used for predicting clinically significant fistulas within the radiomic model (Group 3)

Model	ROC AUC	PR AUC	Accuracy, %	Precision, %	Recall, %	F1 Score, %	Sensitivity, %	Specificity, %
Optimized Random Forest	0.738	0.694	78	60	60	60	60	85
Gradient Boosting	0.631	0.557	61	38	60	46	60	62
XGBoost	0.677	0.720	72	50	60	55	60	77
LightGBM	0.631	0.709	61	38	60	46	60	62
Stacking	0.662	0.644	67	43	60	50	60	69
AdaBoost	0.815	0.772	61	40	80	53	80	54

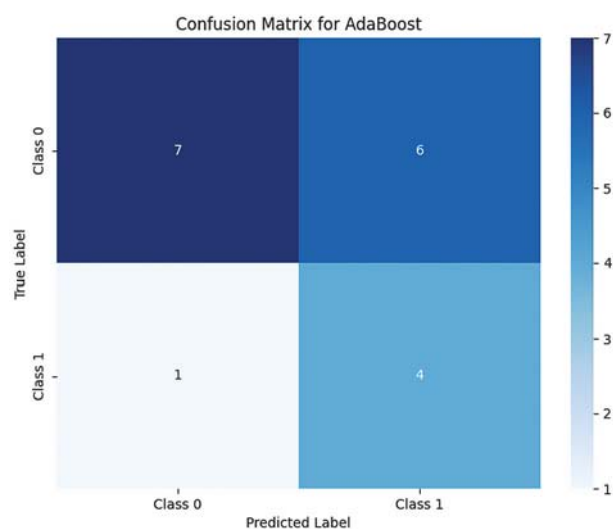



Рис. 6. Матрица решений модели AdaBoost: результаты классификации.

Fig. 6. Confusion matrix of the AdaBoost model: classification results.

в условиях, где ключевой задачей является предотвращение ложноотрицательных диагнозов. Результаты классификации модели AdaBoost представлены на рис. 6.

Optimized Random Forest демонстрирует оптимальный баланс метрик (F1 60%, специфичность 84,6%, см. таблицу) и может быть рекомендован для сценариев, где важна устойчивость модели. Остальные алгоритмы (XGBoost, LightGBM, Gradient Boosting, Stacking) либо уступают по ключевым показателям, либо имеют выраженный дисбаланс между Precision и Recall, что ограничивает их клиническую применимость.

Необходимо отметить, что данное исследование проводилось на ограниченной выборке, что предполагает необходимость дальнейшего изучения вопроса для более полной и достоверной оценки результатов. Таким образом, использование методов машинного обучения позволяет достигать более высоких показателей эффективности моделей. Однако разработка таких моделей может требовать значительных объемов данных для обучения. Кроме того, алгоритмы машинного обучения обладают меньшей прозрачностью в плане интерпретации логики, лежащей в основе принимаемых решений, что затрудняет отслеживание “аргументации” предсказаний. Для решения этого вопроса необходимо проведение детального анализа внутренней структуры конкретных моделей, что способствует повышению уровня доверия со стороны клинических специалистов и врачей-рентгенологов.

Обсуждение


В настоящее время наиболее распространенными прогностическими моделями для оценки риска ПОПФ являются шкалы риска ее развития (Fistula Risk Score – FRS): альтернативная FRS (a-FRS) и обновленная альтернативная FRS (ua-FRS). В их основе лежат интраоперационные данные, такие как плотность поджелудочной железы и диаметр панкреатического протока. В оригинальной версии FRS учитывалась интраоперационная кровопотеря, однако данные о ее связи с ПОПФ оказались противоречивыми, поэтому данный параметр был исключен из последующих моделей. Одной из ключевых проблем ранее созданных моделей является их интраоперационная направленность, а в некоторых случаях – использование послеоперационных данных, таких как гистологические или лабораторные показатели. Интраоперационная оценка риска ограничивает возможности предоперационного планирования, информирования пациентов, проведения рандомизации и других этапов подготовки.

За последние 10 лет предложено множество моделей, направленных на предоперационное прогнозирование панкреатической фистулы. Однако лишь модели, разработанные G. Perri и соавт. и Y. Shi и соавт., прошли внешнюю валидацию, продемонстрировав показатели AUROC 0,65 и 0,81 соответственно [34, 35]. Остальные модели не были валидированы, что делает оценку их эффективности менее надежной.

G. Perri и соавт. предложили модель в виде дерева решений, основанную на диаметре панкреатического протока (\geq или < 5 мм) и индексе массы тела (ИМТ \geq или < 25) [34]. Однако такие модели имеют методологические ограничения, связанные с дихотомизацией предикторов, что часто приводит к снижению их эффективности при внешней валидации.

Y. Shi и соавт. модифицировали систему FRS и разработали модель CT-FRS, которая в значительной степени опирается на предоперационную оценку КТ-изображений. В рамках данной модели ключевыми параметрами являлись диаметр главного панкреатического протока, объем резецированной паренхимы, площадь культи поджелудочной железы, степень жировой инфильтрации и атрофии, оцененные по данным КТ [35].

Y. Shi и соавт. выявили значимую корреляцию риска развития ПОПФ с гистологическими признаками, такими как выраженная липоматозная трансформация, обилие железистых ацинусов и меньшая степень фиброза поджелудочной железы [35]. Данный подход имеет существенное ограничение, так как прогноз возможен только после



выполнения хирургического вмешательства или биопсии, что делает его неприменимым на дооперационном этапе. Напротив, наша радиомическая модель позволяет оценить риск развития ПОПФ неинвазивно на основе предоперационных данных, включая радиомические признаки, что дает хирургу возможность заблаговременно оценить риски и оптимизировать тактику лечения.

В проведенном ранее нами в НМИЦ хирургии им. А.В. Вишневского исследовании [14–16] были выявлены рентгенологические КТ-признаки, которые могут служить маркерами повышенного риска развития панкреатических свищей после резекции поджелудочной железы, например толщина железы $> 17,5$ мм, диаметр протока $< 3,25$ мм, плотность $< 39,5$ HU, а также КН контраста в различных фазах (например, $КН_{вен.}$ менее 0,7 ассоциирован с развитием панкреатита; $КН_{выд.}$ более 0,54 указывает на повышенный риск формирования панкреатических свищей).

Данные факторы риска дают возможность оценить вероятность развития ПОПФ в рамках общей статистики, но не позволяют сделать точный прогноз для конкретного пациента. В то же время предложенная нами модель предполагает персонализированный подход, с высокой диагностической точностью прогнозирует риск развития ПОПФ у каждого отдельного пациента, что существенно повышает клиническую ценность нашего метода.

В литературе существует исследование, подобное нашему, в котором Z. Lin и соавт. разработали и валидировали две модели, радиомическую и комбинированную, для предоперационного прогнозирования клинически значимой послеоперационной панкреатической фистулы у пациентов, перенесших панкреатодуоденэктомию, с последующим сравнением их прогностической эффективности с традиционной системой FRS [30]. Комбинированная модель включала демографические данные, радиомические признаки и рентгенологические КТ-параметры.

Автоматическая сегментация поджелудочной железы на КТ-изображениях была выполнена с использованием методов машинного обучения, в частности глубокого обучения, а именно предобученной 3D U-Net модели. Для построения радиомической модели в качестве классификатора был использован метод AdaBoost.

В нашем исследовании, как и в работе Z. Lin и соавт., также применялись методы машинного обучения, включая AdaBoost. Однако наш подход имеет существенные отличия. В отличие от исследования Z. Lin и соавт., где AdaBoost использовался как отдельный классификатор, нами были дополнительно применены другие сложные ансам-

блевые модели, такие как Stacking Classifier, который объединяет несколько алгоритмов (Random Forest, Gradient Boosting и XGBoost) для повышения точности и устойчивости прогнозов. Кроме того, для устранения дисбаланса классов был применен метод SMOTE (Synthetic Minority Oversampling Technique). Эти подходы позволили значительно улучшить прогностическую способность модели, особенно в условиях значительного дисбаланса классов.


Как и в нашем исследовании, результаты Z. Lin и соавт. продемонстрировали высокую прогностическую способность комбинированной модели: она достигла AUC 0,871 (95% ДИ 0,816–0,926) в обучающей выборке и 0,869 (95% ДИ 0,779–0,958) в валидационной выборке.

В отличие от предыдущих исследований, где пациенты были разделены на группы с наличием и отсутствием ПОПФ, Z. Lin и соавт. определяли риск развития клинически значимой фистулы. Наше исследование также нацелено на предоперационное прогнозирование клинически значимого панкреатического свища. Такие работы имеют высокое практическое значение, так как их результаты позволяют на предоперационном этапе неинвазивно идентифицировать пациентов с высоким риском развития клинически значимой фистулы.

До настоящего времени не существовало комплексной системы поддержки врачебных решений, которая была бы основана на интеграции радиомики и искусственного интеллекта. Впервые коллективом авторов НМИЦ хирургии им. А.В. Вишневского была разработана такая система в рамках платформы “Виртуальная биопсия”. Радиомическая модель, построенная на анализе текстурных признаков, позволяет не только повысить точность прогнозирования клинически значимой ПОПФ, но и предоставить клиницистам инструмент для персонализированного подхода к каждому пациенту, что способствует оптимизации хирургической тактики, минимизации рисков и улучшению исходов лечения.

Заключение

Предыдущие исследования прогнозирования панкреатических фистул после ПДР опирались на интраоперационные параметры (FRS) или ограниченные семантические КТ-признаки, что снижало их предоперационную применимость. Нерешенными остаются задачи создания неинвазивных, объективных инструментов, интегрирующих количественные данные визуализации для точной стратификации рисков. В данном исследовании разработаны 5 моделей для предоперационного прогнозирования клинически значимой послеопе-



рационной панкреатической фистулы у пациентов, перенесших ПДР: две КТ-морфологические, включающие полный и селективный набор морфологических параметров, радиомическая на основе текстурных показателей, мультимодальная комбинированная, объединяющая полный морфологический набор с радиомическими данными, и оптимизированная гибридная модель, объединяющая селективные морфологические маркеры с радиомикой. Наивысшую эффективность показала радиомическая модель, которая может стать полезным инструментом для принятия клинических решений и улучшения прогноза пациентов. Выявлено, что данные радиомического анализа обладают большей прогностической ценностью, чем семантические признаки. Таким образом, методы машинного обучения представляют собой эффективный инструмент для предсказания риска развития клинически значимой панкреатической фистулы после ПДР. Эти алгоритмы позволяют более эффективно учитывать сложные взаимосвязи между признаками, однако для дальнейшего углубленного изучения данной проблемы требуется расширение объема данных.

Участие авторов

Кондратьев Е.В. – концепция и дизайн исследования, подготовка и редактирование текста, ответственность за целостность всех частей статьи, утверждение окончательного варианта статьи, участие в научном дизайне.

Мазурок А.В. – сбор и обработка данных, обзор публикаций по теме статьи, подготовка и редактирование текста, написание текста, подготовка, создание опубликованной работы.

Усталов А.А. – статистическая обработка данных, анализ и интерпретация полученных данных, проведение исследования, подготовка и редактирование текста, написание текста, участие в научном дизайне.

Шмелева С.А. – статистическая обработка данных, анализ и интерпретация полученных данных, проведение исследования, участие в научном дизайне.

Стручков В.Ю. – подготовка и редактирование текста, участие в научном дизайне, проведение исследования, утверждение окончательного варианта статьи.

Марков П.В. – подготовка и редактирование текста, ответственность за целостность всех частей статьи, утверждение окончательного варианта статьи, участие в научном дизайне.

Синицын В.Е. – подготовка и редактирование текста, утверждение окончательного варианта статьи, участие в научном дизайне.

Authors' participation

Kondratyev E.V. – concept and design of the study, text preparation and editing, responsibility for the integrity of all parts of the article, approval of the final version of the

article, participation in scientific design, preparation and creation of the published work.

Mazurok A.V. – collection and analysis of data, review of publications, text preparation and editing, writing text, preparation and creation of the published work.

Ustalov A.A. – statistical analysis, analysis and interpretation of the obtained data, conducting research, text preparation and editing, writing text, participation in scientific design.

Shmeleva S.A. – statistical analysis, analysis and interpretation of the obtained data, conducting research, participation in scientific design.


Struchkov V.Y. – text preparation and editing, participation in scientific design, conducting research, approval of the final version of the article.

Markov P.V. – text preparation and editing, responsibility for the integrity of all parts of the article, approval of the final version of the article, participation in scientific design.


Sinitsyn V.E. – text preparation and editing, approval of the final version of the article, participation in scientific design.

Список литературы [References]

1. Патютко Ю.И., Котельников А.Г., Поляков А.Н., Подлужный Д.В. Эволюция хирургии рака головки поджелудочной железы и периампиллярной зоны. *Анналы хирургической гепатологии*. 2019; 24 (3): 45–53. <http://doi.org/10.16931/1995-5464.2019345-53>
2. Patyutko Yu.I., Kotelnikov A.G., Polyakov A.N., Podluzhnyi V.D. Evolution of surgery for pancreatic head and periampullary cancer. *Annals of HPB Surgery*. 2019; 24 (3): 45–53. <http://doi.org/10.16931/1995-5464.2019345-53> (In Russian)
3. Angileri S.A., Gorga G., Tortora S. et al. Biliary injuries after pancreatic surgery: interventional radiology management. *Gland Surg*. 2019; 8 (2): 141–149. <http://doi.org/10.21037/gs.2019.01.05>
4. Kapoor V.K. Complications of pancreatoduodenectomy. *Rozhl. Chir*. 2016; 95 (2): 53–59.
5. Tonolini M., Ierardi A.M., Carrafiello G. Elucidating early CT after pancreatoduodenectomy: a primer for radiologists. *Insights Imaging*. 2018; 9 (4): 425–436. <http://doi.org/10.1007/s13244-018-0616-3>
6. Chincarini M., Zamboni G.A., Pozzi Mucelli R. Major pancreatic resections: normal postoperative findings and complications. *Insights Imaging*. 2018; 9 (2): 173–187. <http://doi.org/10.1007/s13244-018-0595-4>
7. Кабанов М.Ю., Семенов К.В., Яковлева Д.М., Алексеев В.В. Состояние проблемы развития панкреатической фистулы у пациентов, перенесших панкреатодуоденальную резекцию. *Вестник Национального медико-хирургического центра им. Н.И. Пирогова*. 2017; 12 (2): 112–116. <http://doi.org/10.25881/BPNMSC.2017.12.2.112.116>
8. Kabanov M.Yu., Sementsov K.V., Yakovleva D.M., Alekseev V.V. Current issues of pancreatic fistula development in patients after pancreatoduodenectomy. *Bulletin of the Pirogov National Medical and Surgical Center*. 2017; 12 (2): 112–116. <http://doi.org/10.25881/BPNMSC.2017.12.2.112.116> (In Russian)
9. Райн В.Ю. Билиарная фистула после панкреатодуоденальной резекции. *Новости хирургии*. 2022; 30 (1): 95–101. <http://doi.org/10.16931/1995-5464.2022-30-1-95-101>



- Rayn V.Yu. Biliary fistula after pancreaticoduodenectomy. *Surgery News*. 2022; 30 (1), 95–101. <http://doi.org/10.16931/1995-5464.2022-30-1-95-101> (In Russian)
8. Lowy A.M., Lee J.E., Pisters P.W. et al. Prospective, randomized trial of octreotide to prevent pancreatic fistula after pancreaticoduodenectomy for malignant disease. *Ann. Surg.* 1997; 226 (5): 632–641. <http://doi.org/10.1097/0000658-199711000-00008>
9. Braga M., Capretti G., Pecorelli N. et al. A prognostic score to predict major complications after pancreaticoduodenectomy. *Ann. Surg.* 2011; 254 (5): 702–707. <http://doi.org/10.1097/SLA.0b013e31823598fb>
10. Bassi C., Marchegiani G., Dervenis C. et al. The 2016 update of the International Study Group (ISGPS) definition and grading of postoperative pancreatic fistula: 11 years after. *Surgery*. 2017; 161 (3): 584–591. <http://doi.org/10.1016/j.surg.2016.11.014>
11. Fu S.J., Shen S.L., Li S.Q. et al. Risk factors and outcomes of postoperative pancreatic fistula after pancreaticoduodenectomy: an audit of 532 consecutive cases. *BMC Surg.* 2015; 15: 117. <http://doi.org/10.1186/s12893-015-0011-7>
12. Hallet J., Zih F.S., Deobald R.G. et al. The impact of pancreaticojejunostomy versus pancreaticogastrostomy reconstruction on pancreatic fistula after pancreaticoduodenectomy: meta-analysis of randomized controlled trials. *HPB*. 2015; 17 (2): 113–120. <http://doi.org/10.1111/hpb.12299>
13. Casadei R., Ricci C., Taffurelli G. et al. Are there preoperative factors related to a “soft pancreas” and are they predictive of pancreatic fistulas after pancreatic resection? *Surg. Today*. 2015; 45 (6): 708–714. <http://doi.org/10.1007/s00595-014-1045-7>
14. Гальчина Ю.С., Кондратьев Е.В., Кармазановский Г.Г. и др. КТ-предикторы послеоперационных специфических осложнений при резекциях поджелудочной железы. *Российский электронный журнал лучевой диагностики*. 2020; 10 (2): 102–115. <http://doi.org/10.21569/2222-7415-2020-10-2-102-115>
- Galchina Y.S., Kondratyev E.V., Karmazanovsky G.G. et al. CT predictors of postoperative specific complications in pancreatic resections. *Russian Electronic Journal of Radiology*. 2020; 10 (2): 102–115. <http://doi.org/10.21569/2222-7415-2020-10-2-102-115> (In Russian)
15. Гальчина Ю.С., Кармазановский Г.Г., Кондратьев Е.В., Горин Д.С., Галкин Г.В., Кригер А.Г. Возможность компьютерной томографии с контрастным усилением в оценке объема культи поджелудочной железы при панкреатодуоденальной резекции. *Хирургия. Журнал им. Н.И. Пирогова*. 2020; 6: 31–37. <http://doi.org/10.17116/hirurgia202006131>
- Galchina Yu.S., Karmazanovsky G.G., Kondratyev E.V. et al. Contrast-enhanced computed tomography in evaluation of pancreatic stump volume in pancreaticoduodenectomy. *Pirogov Russian Journal of Surgery = Khirurgiya. Zhurnal imeni N.I. Pirogova*. 2020; 6: 31–37. <http://doi.org/10.17116/hirurgia202006131> (In Russian)
16. Гальчина Ю.С., Кармазановский Г.Г., Калинин Д.В., Кондратьев Е.В., Горин Д.С., Галкин Г.В., Кригер А.Г. Критерии диагностики “мягкой” поджелудочной железы и их влияние на возникновение панкреатического свища после панкреатодуоденальной резекции. *Анналы хирургической гепатологии*. 2020; 25 (2): 113–123. <http://doi.org/10.16931/1995-5464.20202113-123>
- Galchina Y.S., Karmazanovsky G.G., Kalinin D.V. et al. Diagnostic criteria for a “soft” pancreas and their influence on the occurrence of pancreatic fistula after pancreatoduodenectomy. *Annals of HPB Surgery*. 2020; 25 (2): 113–123. <http://doi.org/10.16931/1995-5464.20202113-123> (In Russian)
17. Lee S.E., Jang J.Y., Lim C.S. et al. Measurement of pancreatic fat by magnetic resonance imaging: predicting the occurrence of pancreatic fistula after pancreatoduodenectomy. *Ann. Surg.* 2010; 251 (5): 932–936. <http://doi.org/10.1097/SLA.0b013e3181d65483>
18. Watanabe H., Kanematsu M., Tanaka K. et al. Fibrosis and postoperative fistula of the pancreas: correlation with MR imaging findings—preliminary results. *Radiology*. 2014; 270 (3): 791–799. <http://doi.org/10.1148/radiol.13131194>
19. Råty S., Sand J., Lantto E. et al. Postoperative acute pancreatitis as a major determinant of postoperative delayed gastric emptying after pancreaticoduodenectomy. *J. Gastrointest. Surg.* 2006; 10 (8): 1131–1139. <http://doi.org/10.1016/j.gassur.2006.05.012>
20. El Nakeeb A., Hamdy E., Sultan A.M. et al. Isolated Roux loop pancreaticojejunostomy versus pancreaticogastrostomy after pancreaticoduodenectomy: a prospective randomized study. *HPB (Oxford)*. 2014; 16 (8): 713–722. <http://doi.org/10.1111/hpb.12210>
21. Deng Y., Zhao B., Yang M. et al. Association between the incidence of pancreatic fistula after pancreaticoduodenectomy and the degree of pancreatic fibrosis. *J. Gastrointest. Surg.* 2018; 22 (3): 438–443. <http://doi.org/10.1007/s11605-017-3660-2>
22. Kim S.Y., Kim H., Cho J.Y. et al. Quantitative assessment of pancreatic fat by using unenhanced CT: pathologic correlation and clinical implications. *Radiology*. 2014; 271 (1): 104–112. <http://doi.org/10.1148/radiol.13122883>
23. Roberts K.J., Storey R., Hodson J. et al. Pre-operative prediction of pancreatic fistula: is it possible? *Pancreatol.* 2013; 13 (4): 423–428. <http://doi.org/10.1016/j.pan.2013.04.322>
24. Hashimoto Y., Sclabas G.M., Takahashi N. et al. Dual-phase computed tomography for assessment of pancreatic fibrosis and anastomotic failure risk following pancreatoduodenectomy. *J. Gastrointest. Surg.* 2011; 15 (12): 2193–2204. <http://doi.org/10.1007/s11605-011-1687-3>
25. Кондратьев Е.В., Шмелева С.А., Усталов А.А., Гурина В.И., Кармазановский Г.Г. Теоретические основы текстурного анализа КТ-изображений образований органов брюшной полости: обзор. *Лучевая диагностика и терапия*. 2025; 1: 33–46. <http://doi.org/10.22328/2079-5343-2025-16-1-33-46>
- Kondratyev E.V., Shmeleva S.A., Ustulov A.A. et al. Theoretical basics of abdominal CT radiomics: a review. *Diagnostic Radiology and Radiotherapy*. 2025; 16 (1): 33–46. <http://doi.org/10.22328/2079-5343-2025-16-1-33-46> (In Russian)
26. Васильев Ю.А., Владимирский А.В., Омелянская О.В., Решетников Р.В., Блохин И.А., Коденко М.Р., Нанова О.Г. Обзор метаанализов о применении искусственного интеллекта в лучевой диагностике. *Медицинская визуализация*. 2024; 28 (3): 22–41. <http://doi.org/10.24835/1607-0763-1425>
- Vasilev Y.A., Vladzimirsky A.V., Omelyanskaya O.V. et al. Review of meta-analyses on the use of artificial intelligence in radiology. *Medical Visualization*. 2024; 28 (3): 22–41. <http://doi.org/10.24835/1607-0763-1425> (In Russian)



27. Гележе П.Б., Блохин И.А., Семенов С.С., Caruso D. Радиомика магнитно-резонансной томографии при раке предстательной железы: что известно в настоящее время? *Digital Diagnostics*. 2021; 2 (4): 441–452. <http://doi.org/10.17816/DD70170>
- Gelezhe P.B., Blokhin I.A., Semenov S.S., Caruso D. Magnetic resonance imaging radiomics in prostate cancer radiology: what is currently known? *Digital Diagnostics*. 2021; 2 (4): 441–452. <http://doi.org/10.17816/DD70170> (In Russian)
28. Гележе П.Б., Блохин И.А., Семенов С.С. Радиомика для диагностики и лечения рака предстательной железы. *Медицинская физика*. 2022; 1: 21.
- Gelezhe P.B., Blokhin I.A., Semenov S.S. Radiomics for the diagnosis and treatment of prostate cancer. *Medical Physics*. 2022; 1: 21. (In Russian)
29. Kambakamba P., Mannil M., Herrera P.E. et al. The potential of machine learning to predict postoperative pancreatic fistula based on preoperative, non-contrast-enhanced CT: a proof-of-principle study. *Surgery*. 2020; 167 (2): 448–454. <http://doi.org/10.1016/j.surg.2019.09.019>
30. Lin Z., Tang B., Cai J. et al. Preoperative prediction of clinically relevant postoperative pancreatic fistula after pancreaticoduodenectomy. *Eur. J. Radiol.* 2021; 139: 109693. <http://doi.org/10.1016/j.ejrad.2021.109693>
31. Суворов В.А., Панин С.И., Коваленко Н.В. и др. Прогнозирование панкреатической фистулы после панкреатодуоденальной резекции с использованием машинного обучения. *Сибирский онкологический журнал*. 2023; 22 (6): 25–34. <http://doi.org/10.21294/1814-4861-2023-22-6-25-34>
- Suvorov V.A., Panin S.I., Kovalenko N.V. et al. Prediction of pancreatic fistula after pancreaticoduodenectomy using machine learning. *Siberian Journal of Oncology*. 2023; 22 (6): 25–34. <http://doi.org/10.21294/1814-4861-2023-22-6-25-34> (In Russian)
32. Van Griethuysen J.J.M., Fedorov A., Parmar C. et al. Computational radiomics system to decode the radiographic phenotype. *Cancer Res*. 2017; 77 (21): e104–e107. <http://doi.org/10.1158/0008-5472.CAN-17-0339>
33. Fedorov A., Beichel R., Kalpathy-Cramer J. et al. 3D Slicer as an image computing platform for the quantitative imaging network. *Magn. Reson. Imaging*. 2012; 30 (9): 1323–1341. <http://doi.org/10.1016/j.mri.2012.05.001>
34. Perri G., Marchegiani G., Partelli S. et al. Preoperative risk stratification of postoperative pancreatic fistula: a risk-tree predictive model for pancreaticoduodenectomy. *Surgery*. 2021; 170 (6): 1596–1601. <http://doi.org/10.1016/j.surg.2021.06.046>
35. Shi Y., Gao F., Qi Y. et al. Computed tomography-adjusted fistula risk score for predicting clinically relevant postoperative pancreatic fistula after pancreaticoduodenectomy: training and external validation of model upgrade. *EBioMedicine*. 2020; 62: 103096. <http://doi.org/10.1016/j.ebiom.2020.103096>

Для корреспонденции*: Мазурок Алина Вадимовна – e-mail: alvmazurok@mail.ru

Кондратьев Евгений Валерьевич – канд. мед. наук, заведующий отделением рентгенологии ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0000-0001-7070-3391>. E-mail: evgenykondratiev@gmail.com

Мазурок Алина Вадимовна – врач-ординатор отделения рентгенологии и магнитно-резонансных исследований ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0000-0001-6032-2130>. E-mail: alvmazurok@mail.ru

Усталов Андрей Александрович – младший научный сотрудник отделения рентгенологии и магнитно-резонансных исследований ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <http://orcid.org/0009-0005-9267-8584>. E-mail: andreiushtalov@gmail.com

Шмелева София Антоновна – врач-ординатор отделения рентгенологии и магнитно-резонансных исследований ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <http://orcid.org/0009-0007-5724-2763>. E-mail: sofiaantonovna@gmail.com

Стручков Владимир Юрьевич – канд. мед. наук, младший научный сотрудник отделения абдоминальной хирургии ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0000-0003-1555-1596>. E-mail: doc.struchkov@gmail.com

Марков Павел Викторович – доктор мед. наук, заведующий отделением абдоминальной хирургии ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0000-0002-9074-5676>. E-mail: markov@ixv.ru

Синицын Валентин Евгеньевич – доктор мед. наук, профессор, заведующий кафедрой лучевой диагностики и терапии факультета фундаментальной медицины ФГБОУ ВО “Московский государственный университет имени М.В. Ломоносова”, Москва. <http://orcid.org/0000-0002-5649-2193>. E-mail: vsini@mail.ru

Contact*: Alina V. Mazurok – e-mail: alvmazurok@mail.ru

Evgeny V. Kondratyev – Cand. of Sci. (Med.), Head of the Diagnostic Radiology Department, A.V. Vishnevsky National Medical Research Center of Surgery, Moscow. <https://orcid.org/0000-0001-7070-3391>. E-mail: evgenykondratiev@gmail.com

Alina V. Mazurok – Resident Physician of radiology department, A.V. Vishnevsky National Medical Research Center of Surgery, Moscow. <https://orcid.org/0000-0001-6032-2130>. E-mail: alvmazurok@mail.ru

Andrey A. Ustalov – the junior research of radiology department, A.V. Vishnevsky National Medical Research Center of Surgery, Moscow. <http://orcid.org/0009-0005-9267-8584>. E-mail: andreiushtalov@gmail.com

Sofia A. Shmeleva – Resident Physician of radiology department, A.V. Vishnevsky National Medical Research Center of Surgery, Moscow. <http://orcid.org/0009-0007-5724-2763>. E-mail: sofiaantonovna@gmail.com

Vladimir Yu. Struchkov – Cand. of Sci. (Med.), Junior Researcher, Department of Abdominal Surgery, A.V. Vishnevsky National Medical Research Center of Surgery, Moscow. <https://orcid.org/0000-0003-1555-1596>. E-mail: doc.struchkov@gmail.com

Pavel V. Markov – Doct. of Sci. (Med.), Head of the Department of Abdominal Surgery, A.V. Vishnevsky National Medical Research Center of Surgery, Moscow. <https://orcid.org/0000-0002-9074-5676>. E-mail: markov@ixv.ru

Valentin E. Sinitsyn – Doct. of Sci. (Med.), Professor, Head of the Department of Radiology and Radiodiagnostics, Faculty of Fundamental Medicine, Lomonosov Moscow State University, Moscow. <http://orcid.org/0000-0002-5649-2193>. E-mail: vsini@mail.ru