

А.А. Пранович¹, Г.Г. Кармазановский¹, Е.С. Сирота²,
М.А. Фирсов³, П.А. Симонов³,
А.И. Юнкер³, М.Х. Джатдоева¹, Д.А. Хубиев⁴

¹Национальный медицинский исследовательский центр хирургии имени А.В. Вишневского, Москва, Российская Федерация

²Первый Московский государственный медицинский университет имени И.М. Сеченова (Сеченовский Университет), Москва, Российская Федерация

³Красноярский государственный медицинский университет им. проф. В.Ф. Войно-Ясенецкого Минздрава России, Красноярск, Российская Федерация

⁴Центр медицинской помощи «DocCity», Черкесск, Российская Федерация

Радиомика при мочекаменной болезни: систематический обзор текущих применений, ограничений и будущих направлений

Приведенный анализ доступных в международной литературе исследований показывает, что применение радиомики при мочекаменной болезни представляет собой быстро развивающееся направление в медицинской науке. Судя по общему числу исследований, включенных в настоящий обзор, очевидно, что диагностические приложения, которые связаны с лучевой диагностикой, в основном близки к внедрению в урологическую практику, в то время как во многих работах авторы утверждали, что функция предложенной ими модели может быть дополнительно оптимизирована после введения большего количества данных. Текстуальный анализ изображений камней значительно повысил точность прогнозирования типа камня в почках. Такие достижения в области технологий медицинской визуализации и машинного обучения, вероятно, будут более широко использоваться в рутинном клиническом лечении мочекаменной болезни в ближайшем будущем. Тем не менее еще есть возможности для дальнейшего совершенствования алгоритмов машинного обучения в целях повышения чувствительности и специфичности методов автоматической классификации.

Ключевые слова: мочекаменная болезнь, радиомика, текстуальный анализ, машинное обучение, искусственный интеллект

Для цитирования: Кармазановский Г.Г., Пранович А.А., Сирота Е.С., Фирсов М.А., Симонов П.А., Юнкер А.И., Джатдоева М.Х., Хубиев Д.А. Радиомика при мочекаменной болезни: систематический обзор текущих применений, ограничений и будущих направлений. Вестник РАМН. 2024;79(4):XXX–XXX. doi: <https://doi.org/10.15690/vramn17953>

Введение

Общемировая заболеваемость мочекаменной болезнью (МКБ) составляет 56,67 случая на 100 тыс. населения. По данным исследовательского центра по изучению глобального бремени болезней (GBD), включающим

204 страны, за 2019 г. наибольшая распространенность МКБ зафиксирована в странах Восточной Европы и на территории Российской Федерации [1]. При этом прогнозируется, что до 15% населения в мире столкнется с данным заболеванием в течение жизни [2, 3]. Российская группа ученых (А.Д. Каприн и соавт., 2022) провели

G.G. Karmazanovsky¹, A.A. Pranovich¹, E.S. Sirota², M.A. Firsov³, P.A. Simonov³,
A.I. Junker³, M.H. Dzhatdоеva¹, D.A. Khubiev⁴

¹A.V. Vishnevsky National Medical Research Center of Surgery, Moscow, Russian Federation

²I.M. Sechenov First Moscow State Medical University (Sechenov University), Moscow, Russian Federation

³V.F. Voyno-Yasenetsky Krasnoyarsk State Medical University, Krasnoyarsk, Russian Federation

⁴Medical Care Center “DocCity”, Cherkessk, Karachay-Cherkess Republic, Russian Federation

Radiomics in Urolithiasis: a Systematic Review of Current Applications, Limitations and Future Directions

Radiomic image analysis of kidney stones has significantly improved the accuracy of kidney stone type prediction. Such advances in medical imaging technologies and machine learning are likely to be more widely used in routine clinical management of KSD in the near future. However, there is still room for further improvement of machine learning algorithms to improve the sensitivity and specificity of automatic classification methods. Creating a network of centralized database for each type of stone, including demographic and general information about patients, urine, blood parameters, other laboratory tests, treatment methods and their results, will allow the development of a more reliable machine learning algorithm for personalized medicine for KSD.

Keywords: urolithiasis, radiomics, machine learning, artificial intelligence

For citation: Karmazanovsky GG, Pranovich AA, Sirota ES, Firsov MA, Simonov PA, Junker AI, Dzhatdоеva MH, Khubiev DA. Radiomics in Urolithiasis: a Systematic Review of Current Applications, Limitations and Future Directions. Annals of the Russian Academy of Medical Sciences. 2024;79(4):XXX–XXX. doi: <https://doi.org/10.15690/vramn17953>




Рис. 1. Последовательность рабочего процесса радиномики

эпидемиологическое исследование, в котором изучена заболеваемость мочекаменной болезнью в РФ с 2005 по 2020 г. Одним из результатов исследования явилось то, что заболеваемость и распространенность МКБ среди взрослого населения неуклонно растет во всех регионах Российской Федерации, а заболеваемость среди детей остается стабильной. Причины этого факта обсуждаются и в настоящее время окончательно неизвестны [4].

Экспоненциальный рост цифровизации медицины привел к тому, что сектор здравоохранения начал использовать искусственный интеллект (ИИ) для управления и оптимизации сбора и использования данных. Применение возможностей ИИ в контексте медицинской визуализации известно как радиномика. Радиномика — это количественный метод, который извлекает обширные объемы полезных данных из медицинских и рентгенографических изображений. На основе радиномики создаются модели обучения, которые используются в алгоритмах характеристики данных, такие как машинное обучение, глубокое машинное обучение и искусственные нейронные сети [5].

Одними из перспективных направлений применения машинного обучения в диагностике МКБ являются обработка медицинских изображений и постановка диагноза на этой основе. «Золотой стандарт» диагностики МКБ — проведение компьютерной томографии (КТ) с получением данных в отраслевом стандарте DICOM (Digital Imaging and Communications in Medicine) с теговой организацией «пациент–исследование–серия–изображение (кадр или серия изображений)». КТ-изображение является результатом вычислений, а не проекционным теневым изображением. Учитывая сложность интерпретации полученных изображений с учетом несколько тысяч оттенков серого, перспективным представляется использование технологии компьютерного зрения и машинного обучения для решения обозначенных задач [6].

Эти алгоритмы количественно оценивают текстурную информацию, используя методы анализа из области ИИ для анализа больших данных. Большие данные описывают «большие объемы высокоскоростных, сложных и переменных данных, которые требуют передовых методов и технологий для сбора, хранения, распространения, управления и анализа информации» [7].

Радиномика преобразует медицинские изображения в количественные данные, а также предоставляет биомаркеры на основе изображений для помощи в принятии клинических решений и улучшения точной медицины [8]. Целью радиномики является улучшение диагностики за счет использования ИИ для оптимизации диагностической и прогностической информации [9, 10]. Она превосходит человеческую способность идентифицировать ключевые характеристики изображений, незаметные для невооруженного человеческого глаза, собирая скрытые объективные данные, которые могут повлиять на последующие решения о лечении [11].

Успехи в области онкологии привлекли внимание к применению радиномики при доброкачественных урологических заболеваниях, особенно при МКБ. Последовательность рабочего процесса радиномики при МКБ схематично представлена на Рис. 1.

Хотя радиномика при МКБ все еще находится в зачаточном состоянии, она имеет потенциал для широкомасштабного внедрения. Дальнейшее ее развитие может позволить оптимизировать ведение пациентов, создать персонализированные модели профилактики и метафилактики МКБ. Ее наибольший потенциал заключается в корреляции с общепринятыми диагностическими и терапевтическими факторами.

Методика поиска и анализа литературы

331

Обзор медицинской литературы по использованию радиномики при диагностике и лечении МКБ, опубликованной в период с 2000 по 2022 г., был проведен в ноябре 2023 г. с использованием данных информационно-аналитических систем MEDLINE, Scopus, Google Scholar и Web of Science. Стратегия поиска проводилась в соответствии с критериями PICO (пациент–вмешательство–сравнение–исход), согласно которой пациентам с МКБ (P) диагноз валидировался с помощью алгоритмов на основе радиомического анализа и/или тактика лечения выбиралась с применением алгоритмов радиномики, в основе которого лежал текстурный анализ (I) в сравнении с традиционными методами биомедицинской статистики (C) с последующей оценкой достоверности примененных алгоритмов машинного обучения (O).

Для поиска медицинской литературы были использованы следующие ключевые слова: «радиномика», «текстурный анализ», «мочекаменная болезнь», «искусственный интеллект», «нейронные сети», «машинное обучение».

Критерии включения: оригинальные статьи по применению радиномики при МКБ; полнотекстовые статьи по диагностике, планированию лечения, прогнозированию результатов лечения МКБ на основе радиномики.

Критерии исключения: обзорные статьи; отчеты о клинических случаях; аннотации; экспериментальные и лабораторные исследования на животных.

В результате поиска отобрано 89 научных публикаций. После скрининга на соответствие критериям включения было исключено 18 научных публикаций, 61 исследование отобрано для детального анализа.

Результаты анализа литературы

Определение химического состава конкремента

Определение типа камней в почках — важный шаг в лечении МКБ для достижения удовлетворительного терапевтического результата. «Золотым стандартом» определения химического состава камня являются инфра-

красная спектроскопия и рентгеновская дифракция. Оба метода признаны мировым медицинским сообществом надежными и широко используются. Однако данные методы требуют специализированного оборудования, которое имеется только в лабораториях, что сопряжено со значительными финансовыми и временными затратами. Сейчас недостаточно удалить камень тем или иным оперативным методом, так как минералогический состав камня служит основой для диагностики и определения тактики лечения [12]. Степень риска рецидива камнеобразования определяется химическим составом конкремента и тяжестью заболевания [13].

В свою очередь, применение текстурного анализа и глубокого машинного обучения с использованием данных КТ дает уникальную возможность определить химический состав камня неинвазивным методом. Ряд исследователей сообщают об определении состава камней непосредственно по данным КТ-исследований в ручном режиме [14, 15].

J. Zheng et al. разработали радиомическую модель, которая позволила в предоперационном периоде выявить инфекционные камни с дальнейшей валидацией [16]. Были проанализированы КТ-изображения 1198 пациентов с МКБ, и извлечены 24 лучшие радиомические характеристики из 1316, доработанные LASSO. Номограмма показала благоприятную калибровку и распознавание инфекционных камней как в обучающем, так и в трех проверочных наборах (площадь под кривой — 95%; доверительный интервал — соответственно 0,898 (0,840–0,956), 0,832 (0,742–0,923), 0,825 (0,783–0,866) и 0,812 (0,710–0,914)).

Аналогичную работу провели J.S. Kriegshauser et al. [17], оценивая эффективность применения различных алгоритмов машинного обучения для определения состава камня по КТ-изображениям. Были отобраны КТ-изображения 32 камней размером 3–10 мм. Методом инфракрасной спектроскопии определен состав камней с помощью пяти многопараметрических алгоритмов: нейросети, дерева решений (Decision Tree), случайного леса (Random Forest), метода опорных векторов (Support Vector Machine), гибридного алгоритма Байесовского классификатора с деревом решений (Naive Bayes Tree) проанализировано 52 радиомические характеристики. При этом максимальная точность (100%) при определении компонентного состава камня была при классификации конкрементов по содержанию в составе мочевой кислоты. Нейросеть, метод Support Vector Machine и алгоритм Naive Bayes Tree показали наилучшую точность в диагностике состава конкрементов. Противоположный результат выдали алгоритмы Decision Tree и Random Forest. К минусам данных алгоритмов можно отнести то, что при анализе КТ-изображений камней, не содержащих мочевую кислоту, точность диагностики снижается до 75%, что недостаточно для эффективной диагностики.

Кроме того, тип камня можно определять по внешнему виду, текстуре и сечению цифровых изображений компьютерной томографии и цифровой видеосъемки. Так, N. Grosse Nokamp et al. [18] использовали двухэнергетическую КТ и машинное обучение для прогнозирования различного состава камней, включая вевеллит (моногидрат оксалата кальция), вевделлит (дигидрат оксалата кальция), апатит (фосфат кальция), цистин, струвит (фосфат магния и аммония), мочевую кислоту (урицит) и ксантин. H.W. Chen et al. [19] создали прогностическую модель с радиомикронной сигнатурой на основе изображений нативной КТ и независимых кли-

нических предикторов для обнаружения инфекционных камней, где площадь под кривой (AUC) составила 0,825.

В своем исследовании A. Abraham et al. [20] разработали автоматизированную систему детекции, позволяющую при эндоскопии различать шесть типов камней. Используя набор данных микроскопических изображений, полученных со смартфона, E.G. Onal et al. [21] оценили систему распознавания изображений, позволяющую быстро и точно классифицировать четыре типа камней в почках. Аналогично V. Estrade et al. [22] применили метод глубокого обучения к цифровым эндоскопическим видеопоследовательностям для автоматического определения морфологии камня в процессе его фрагментации. Используя клинические характеристики и особенности кишечной микробиоты, L. Xiang et al. [23] предсказали развитие вевеллита (моногидрат оксалата кальция). Указанные исследования, включая их цели, используемые методы ИИ и результаты, обобщены в Табл. 1.

Определение локализации камней и дифференциальная диагностика

Хотя достижения в радиологии улучшили возможности дифференциации флеболитов от камней мочеточника, они по-прежнему представляют собой трудную диагностическую задачу, особенно в неотложных ситуациях, что приводит к ненужному вмешательству и связанным с этим финансовым и ресурсным нагрузкам.

Впервые описанные в XIX в. флеболиты представляют собой слой кальцинированной фиброзной ткани, покрытые слоем эндотелия, который переходит в интимальный слой стенки вены [27]. Отличительными характеристиками флеболита являются центральная прозрачность, признак хвоста кометы и анатомическое распределение [28].

T. De Perrot et al. [29] в своем исследовании провели дифференциальную диагностику между конкрементами мочеточника и флеболитами с помощью улучшения использования низкодозной КТ без контрастного усиления. Были отобраны 369 пациентов с 211 камнями в почках и 201 флеболитом для независимого обучения и 43 пациента с 24 камнями в почках и 23 флеболитами в группе тестирования для обучения и экспериментирования с классификатором машинного обучения. Модель выбрана с использованием стратегии перекрестной проверки, которая позволила выбрать лучший классификатор машинного обучения — AdaBoost. Около 147 029 радиомических показателей, извлеченных из КТ-изображений, были использованы для прогностической модели. Данный классификатор показал высокие показатели чувствительности (91,7%) и специфичности (78,3%) при значении ROC-AUC 0,902, а общая точность составила 85,1%.

Указанное исследование показало хорошие результаты применения текстурного анализа для дифференцировки флеболита и мочевых камней. Но возможно ли применять его для определения наличия конкремента в почках? На данный вопрос дало ответ исследование A. Parakh et al. [30], в котором проведен анализ КТ-изображений для определения наличия конкремента с дальнейшей классификацией по группам в зависимости от размера камня. В исследовании использовались КТ-изображения 535 пациентов с подозрением на МКБ, которые были получены на двух сканерах (S1 и S2). Конкременты присутствовали на 279 снимках и отсутствовали на 256. В качестве тестового набора отобрано по 50 КТ-изображений с каждого сканера, остальные 435 были использованы для разработки каскадных классификаторов. Разработано девять моделей с помощью комбинаций различных ис-

Таблица 1. Краткая характеристика ключевых исследований в определении химического состава камней с использованием методов машинного обучения

Авторы	Цель	Материал	Метод(ы)	Точность, %	Чувствительность, %	Специфичность
Xiang et al., 2021 г. [23]	Прогнозирование оксалатно-кальциевого камня в почках	Пациенты и компонентный состав камня	Машинное обучение (RF)	Н/д	Н/д	Н/д
Kazemi et al., 2017 г. [24]	Прогнозирование типа камня в почках	Пациенты и компонентный состав камня	Машинное обучение (на основе ансамбля данных)	97,10	Н/д	Н/д
Sachl et al., 2019 г. [25]	Прогнозирование состава камней в почках	Компонентный состав камня	Машинное обучение (K-ближайшие соседи)	98,17	98,00	98,60
Grosse Hokamp et al., 2020 г. [18]	Прогнозирование основного компонента чистых и смешанных камней в почках	КТ-изображения	Машинное обучение (поверхностная нейронная сеть)	91,10	Н/д	Н/д
Black et al., 2020 г. [26]	Прогнозирование состава камней в почках	Цифровые фотографии камни	Машинное обучение (ResNet-101)	Н/д	94,12 для мочевой кислоты	97,83 для мочевой кислоты
Zheng et al., 2021 г. [16]	Определение инфекционного камня в естественных условиях	КТ-изображения	Машинное обучение (ЛАССО)	Н/д	Н/д	Н/д
Abraham et al., 2022 г. [20]	Прогнозирование состава камней в почках	Демографические и клинические признаки результаты анализов мочи, КТ-изображения	Машинное обучение (XGBoost)	91,00	26,00	Н/д
Chen et al., 2022 г. [19]	Прогнозирование наличия мочевой кислоты в составе мочевых камней	Клинические параметры, КТ-изображения	Машинное обучение	Н/д	100	91,20
Onal et al., 2022 г. [21]	Прогнозирование состава камней в почках	Микроскопические изображения камня	Глубокое машинное обучение (CNN)	88,00	Н/д	Н/д
Estrade et al., 2022 г. [22]	Прогнозирование состава камней в почках	Эндоскопическое цифровое изображение и видео камня	Глубокое машинное обучение (CNN)	88 ± 6	80 ± 13	92 ± 2

точников обучающих данных. Значение AUC для автоматической детекции конкрементов было от 0,92 до 0,95 в зависимости от модели. Модель GrayNet-SB показала 95%-ю точность по сравнению с ImageNet-SB, где точность составила 91%, и Random-SB — 88%. В исследовании авторами была показана эффективность каскадной сверточной искусственной нейронной сети (ИНС). При использовании этого подхода мочевыводящие пути обнаруживаются с помощью первой модели, а камни — с помощью второй модели указанной нейронной сети.

Интересным также представляется исследование F. Nomaounieh et al. [31], которые в своей работе проанализировали 202 пациента с камнями в почках, которым было проведено КТ-исследование на трех различных аппаратах компьютерной томографии с использованием автономного протокола radiomics. Данное исследование отразило способность автоматически сегментированной рентгеномики всей почки оценить количество камней и стратегию лечения по снимкам КТ и также прогнозировать гидронефроз. Выделено 1690 радиомических характеристик первого и более высокого порядка для каждой почки, которые были проанализированы с использованием логистического регрессионного анализа. Среди 202 только 28 пациентам (18%) потребовалось хирургическое лечение. Матрица сопутствующих заболеваний серого цвета (GLCM) и матрица продолжительности цикла серого цвета (GLRLM) дифференцировали пациентов на группы хирургического лечения и без него (AUC — 0,91; 95%-й ДИ: 0,85–0,92). Рентгеномика более высокого порядка (матрица зон размеров серого уровня — GLSZM) дифференцировала почки с гидронефрозом и без него (AUC — 0,99; $p < 0,001$), а также почки с различным объемом камней (AUC — до 0,89; 95%-й ДИ: 0,89–0,92).

D. Li et al. [32] использовали нативную КТ и глобкое машинное обучение, чтобы исключить ложноположительные области из камней в почках. A. Caglayan et al. [33] изучили эффективность модели глубокого обучения для выявления камней в почках на КТ-изображениях без контрастного усиления в различных плоскостях в зависимости от размера камня. Сагиттальная плоскость обеспечила лучшую чувствительность и специфичность по сравнению с другими плоскостями. M. Långkvist et al. [34] создали алгоритм компьютерного обнаружения, который позволяет выявить камень мочеточника при КТ. Аналогично K. Sudharson et al. [35] разработали алгоритм с использованием классификатора машинного обучения на основе машины опорных векторов (SVM) для выявления камней в почках, кист и опухолей с помощью ультразвукового исследования.

Некоторые исследователи пытались использовать автоматизированное машинное обучение для обнаружения камней в почках. Например, K. Yildirim et al. [36] применили модель глубокого обучения для автоматического обнаружения и локализации камней в почках по данным КТ-изображений в плоскости. Y. Cui et al. [37] также сообщили об автоматическом обнаружении камней в почках на изображениях нативной КТ с использованием глубокого обучения и метода оценки нефролитометрии (STONE). Чтобы справиться с шумом КТ, D.C. Elton et al. [38] использовали искусственную нейронную сеть (модель U-Net) для автоматического обнаружения и количественного определения объема мелких камней на КТ-изображениях в плоскости. R. Babajide et al. [39] проанализировали эффективность метода машинного обучения для автоматического обнаружения и характеристики камней в почках по сравнению с ручной

диагностикой. Данные показали, что алгоритм машинного обучения более точно аппроксимирует границу камня с чувствительностью и специфичностью 100%.

В большинстве исследований камней в почках для диагностики используются различные методы медицинской визуализации, включая рентген, КТ и МРТ. Тем не менее лишь в нескольких исследованиях клинические характеристики использовались для диагностики МКБ. Так, N.L. Kavoussi et al. [40] предложили использовать радиомические характеристики камня, суточную мочу и клинические данные для разработки методов метафилактики. Возраст, пол и индекс массы тела, по мнению исследователей, — три переменные, которые оказывают наибольшее влияние на обучение моделей прогнозирования.

Указанные исследования, включая их цели, используемые методы ИИ и результаты, обобщены в Табл. 2.

Определение тактики лечения и прогнозирование результатов

Лечение МКБ делится на хирургическое и консервативное. Хирургическое лечение включает такие операции, как дистанционная литотрипсия (ДЛТ), контактная уретеролитотрипсия (КУЛТ) и перкутанная нефролитотрипсия (ПНЛ). Одним из основных методов фрагментации мочевых камней без повреждения кожных покровов, при помощи ударных волн, является ДЛТ, в основном используемая для лечения камней малых и средних размеров.

M. Mannil et al. [41] в своем исследовании использовали трехмерный текстурный анализ с алгоритмом Random Forest для дополнительной прогностической информации для успешной ДЛТ. Значимыми переменными были индекс массы тела (AUC — 0,68), размер камня (AUC — 0,58) и расстояние от камня до кожи (AUC — 0,63). Было проанализировано 256 радиомических характеристик каждого камня в почках с использованием пяти широко применяемых моделей машинного обучения. Классификатор Random Forest и характеристики по трехмерному текстурному анализу продемонстрировали AUC, равный 0,79, а включение клинических переменных в модель позволило увеличить точность распознавания до 0,85.

Год спустя эти же авторы в своем исследовании доказали принцип использования КТ-изображений конкрементов с применением текстурного анализа с целью прогнозирования количества ударных волн для распада камней. В данном исследовании было использовано 34 КТ-изображения конкрементов. Различия в размерах камней с разным химическим составом проводилось с помощью теста Краскела–Уоллиса с поправкой Бонферрони для множественных сравнений. Для прогнозирования необходимого количества ударных волн были предложены три модели: линейная регрессия, SMOreg и простая линейная регрессия. Используя среднее количество необходимых ударных волн в качестве порогового значения, коэффициенты корреляции и AUC (0,84), высокая точность для определения количества ударных волн в соответствии с размерами камней и их химическим составом была обнаружена у модели SMOreg (чувствительность — 94%; специфичность — 59%) [42].

Обращает на себя внимание комплексное исследование O. Jemil et al. [43], направленное на прогнозирование результатов ДЛТ. В своей работе авторы использовали шкалу Хаунсфилда и вариации неоднородности камней. В исследование было включено 220 пациентов после ДЛТ. Коэффициент вариации плотности камней и другие пара-

Таблица 2. Краткая характеристика ключевых исследований в диагностике мочекаменной болезни с использованием методов машинного обучения

Авторы	Цель	Материал	Метод(ы)	Точность, %	Чувствительность, %	Специфичность
Långkvist et al., 2018 г. [34]	Обнаружение камней в почках на КТ-изображениях	КТ-изображения	Глубокое машинное обучение (CNN)	Н/д	100,00	Н/д
Parakh et al., 2019 г. [30]	Обнаружение камня мочеочника на КТ-изображениях	КТ-изображения	Глубокое машинное обучение (CNN)	95,00	94,00	96,00
De Perrot et al., 2019 г. [29]	Дифференциация камней в почках и флеболитов на изображениях низкодозной КТ	КТ-изображения	Машинное обучение (AdaBoost)	85,10	91,70	78,30
Cui et al., 2021 г. [37]	Обнаружение и оценка количества камней в почках на основе STONE нефролометрии	КТ-изображения	Глубокое машинное обучение (CNN)	Н/д	95,90	Н/д
Sudharson et al., 2021 г. [35]	Обнаружение аномалий почек по зашумленным ультразвуковым изображениям	УЗИ-изображения	Машинное обучение (SVM) и глубокое машинное обучение (CNN)	87,31 в шуме, уровень 0,02	Н/д	Н/д
Yildirim et al., 2021 г. [36]	Обнаружение камней в почках с помощью коронарных КТ-изображений	КТ-изображения	Машинное обучение (XResNet5)	96,82	95,76	97,00
Elton et al., 2022 г. [38]	Обнаружение камней в почках с помощью коронарных КТ-изображений	КТ-изображения	Глубокое машинное обучение (CNN) и машинное обучение (3DU-сети)	Н/д	86,00	Н/д
Li et al., 2022 г. [32]	Обнаружение камней в почках на КТ-изображениях	КТ-изображения	Машинное обучение (ResUNet)	99,95	96,61	99,97
Babajide et al., 2022 г. [39]	Обнаружение камней в почках и измерение характеристик камней на КТ-изображениях	КТ-изображения	Машинное обучение	Н/д	100,00	100,00
Saglayan et al., 2022 г. [33]	Обнаружение камней в почках на КТ-изображениях в разных плоскостях	КТ-изображения	Машинное обучение (XResNet50)	93,00, для камня размеры > 2 см	Н/д	Н/д

метры, связанные со значениями уменьшения размеров камней и их фрагментации, были изучены в качестве потенциальных предикторов на основе нативной КТ. Успех ДЛТ оценивали через 3 мес с помощью КТ. Логистический регрессионный анализ был проведен для определения факторов, способствующих успеху лечения. Анализ рабочих характеристик приемника показал, что SDVC (AUC — 0,82; 95%-й ДИ: 0,76–0,87; $p < 0,03$), средняя плотность камней (AUC — 0,81; 95%-й ДИ: 0,75–0,87; $p < 0,0001$), максимальная плотность камня (AUC — 0,70; 95%-й ДИ: 0,63–0,78; $p < 0,02$), объем камня (AUC — 0,70; 95%-й ДИ: 0,62–0,77; $p < 0,002$) и большой диаметр (AUC — 0,67; 95%-й ДИ: 0,59–0,74; $p < 0,01$) имели значительную точность прогнозирования от высокой до низкой. Кроме того, было обнаружено, что SDVC успешно предсказывает результат ДЛТ, особенно для пациентов с высокой и средней плотностью камней (AUC — 0,80; 95%-й ДИ: 3,55–28,57; $p < 0,004$). Модель логистической регрессии, в которой найдена формула «вероятности распада камня» (SDP), правильно предсказала успех ДЛТ за один сеанс на 79,1%. Из данного исследования можно сделать вывод, что размер и значения затухания (уменьшение в размерах камня в процессе сеанса ДЛТ) были важными предикторами успеха лечения, а лучшим предиктором был SDVC. Оценка формулы SDP перед ДЛТ может прогнозировать результаты и облегчить принятие решений относительно стратегии лечения.

Машинное обучение также может применяться для прогнозирования результата после ПНЛ. Так, A. Aminsharifi et al. [44] предсказали послеоперационный исход ПНЛ на основе радиомических признаков камня, пред- и послеоперационных переменных с использованием искусственной нейронной сети. Модель может прогнозировать состояние отсутствия камней (SFR) или необходимость дополнительных процедур с чувствительностью и точностью от 81,0 до 98,2%. Более того, программное обеспечение для классификации методов машинного обучения дает лучшие результаты по сравнению с номограммой Guy's Stone Score (GSS) и индексом STONE.

Машинное обучение также использовалось для создания системы поддержки принятия решения (DSS) с целью прогнозирования хирургического успеха. В исследовании T. Shabaniyan et al. [45] были использованы четыре различных метода классификации для разработки DSS. В исследовании показано, что результат PNL может быть прогнозирован с высокой степенью точности (94,8%). V.M.Z. Nameed et al. [46] использовали машинное обучение на основе случайного леса (RF) для разработки системы поддержки принятия решений для прогнозирования состояния отсутствия камней после ПНЛ у пациентов с коралловидными камнями с точностью 81%. Указанные исследования, включая их цели, используемые методы ИИ и результаты, обобщены в Табл. 3.

Анализ алгоритмов машинного обучения

Обзор текущего применения радиомики при МКБ будет неполным без анализа алгоритмов машинного обучения, используемых в урологии, в зависимости от задач, которые стоят перед исследователями и результатов, которых они хотели бы достичь. Прежде всего нужно сказать, что все алгоритмы машинного обучения основаны на использовании методов обучения с учителем. В основном это связано с тем, что большинство реализуемых задач формулируется и рассматривается в виде задач классификации.

Мы выделили основные исследования и отразили их в Табл. 4, где сгруппировали все использованные методы обучения по типу алгоритма.

Из данных табл. 4 видно, что в указанных исследованиях наиболее часто используются самые простые и распространенные алгоритмы классификации, такие как случайный лес, машина опорных векторов, а также ансамблевые алгоритмы. Однако более сложные алгоритмы машинного обучения, такие как искусственная нейронная сеть, глубокая нейронная сеть, сверточная нейронная сеть, основанные не только на анализе функций или изображений, но и на обработке естественного языка и временной эволюции функций, используются намного реже. Это может быть связано с отсутствием больших общедоступных баз данных, которые позволяют использовать более сложные методы машинного обучения.

Обращает на себя внимание, что применяемые авторами методы различаются по типу используемых данных и методам их анализа и обработки. В частности, в случаях когда база данных состоит исключительно из числовых характеристик, полученных из медицинских записей в историях болезни, наиболее часто применяются такие классификаторы, как машина опорных векторов и случайный лес. В случаях когда присутствуют диагностические изображения, тип метода машинного обучения варьирует в зависимости от предварительной обработки, примененной к данным. При минимальной или нулевой предварительной обработке используются такие методы, как сверточная нейронная сеть, в которой модель напрямую анализирует изображение и находит наиболее релевантные функции для его классификации. В исследованиях, где алгоритмы используются для извлечения радиомических особенностей из определенных анатомических областей, применяются классификаторы числовых характеристик. В частности, используются ансамблевые алгоритмы, которые обычно в этих случаях гарантируют лучший результат с точки зрения метрик.

Важный аспект оценки качества работы алгоритма машинного обучения — оценка его производительности. Обсуждению этого вопроса были посвящены работы J. Penny-Dimiri et al. [83] и В. Kocak et al. [85]. В них показано, что сравнение методов, применяемых для одной и той же цели, на основе значений, рассчитанных с использованием разных данных, может ввести в заблуждение. Учитывая вышеизложенное, авторы настоятельно рекомендуют использовать такой показатель, как площадь под кривой (AUC), позволяющий оценить качество модели, поскольку он несет более достоверную информацию, чем просто точность.

Учитывая непрерывную эволюцию исследований в этой области, можно заключить, что при наличии множества существующих применений машинного обучения в урологии, ИИ имеет большой потенциал и обладает универсальностью. Пример возможного применения анализа изображений почек с применением ИИ может быть основан на сочетании нескольких существующих в настоящее время методологий, таких как использование глубокого обучения для обнаружения камней почек, с последующим использованием других методов машинного обучения для их классификации и выбора метода лечения и далее разработкой индивидуальных подходов в метафиллактике.

Однако это не означает, что ограничений по-прежнему нет. Большинство исследований заканчива-

Таблица 3. Краткая характеристика ключевых исследований в определении тактики лечения и прогнозировании результатов при хирургическом лечении пациентов с мочекаменной болезнью с использованием методов машинного обучения

Авторы	Цель	Материал	Метод(ы)	Точность, %	Чувствительность, %	Специфичность
Michaels et al., 1998 г. [47]	Прогнозирование повторного роста камней после ДЛТ	Пациент и характеристики камня	Глубокое машинное обучение (ANNA)	91,00	91,00	92,00
Roulakis et al., 2003 г. [48]	Прогнозирование удаления камней в нижней группе чашечек после ДЛТ	Пациент, характеристики камня и КТ-изображения	Глубокое машинное обучение (ANNA)	92,00	Н/д	Н/д
Gomha et al., 2004 г. [49]	Прогнозирование отсутствия фрагментов камня после ДЛТ	Пациент и характеристики камня	Глубокое машинное обучение (ANNA)	77,70	77,90	75,00
Aminsharif et al., 2017 г. [43]	Прогнозирование различных исходов ПНЛ	Пациент и характеристики камня	Глубокое машинное обучение (ANNA)	98,2	98,0	Н/д
Seckiner et al., 2017 г. [50]	Прогнозирование отсутствия фрагментов камня после ДЛТ	Пациент и характеристики камня	Глубокое машинное обучение (ANNA)	85,48	Н/д	Н/д
Manni et al., 2018–2019 гг. [41, 42]	Прогнозирование отсутствия камней после ДЛТ	Пациент, характеристики камня и КТ-изображения	Глубокое машинное обучение (ANNA)	Н/д	65,00	72,00
Shabaniyan et al., 2019 г. [45]	Прогнозирование послеоперационного исхода ПНЛ	Пациент, характеристики камня и лабораторные данные	Машинное обучение (СВМ)	94,8	100,00	88,90
Nameed et al., 2021 г. [46]	Прогнозирование послеоперационного исхода ПНЛ	Пред- и послеоперационные характеристики пациента	Машинное обучение (RF)	81,00	Н/д	Н/д

Таблица 4. Алгоритмы машинного обучения в урологии

Метод — алгоритм машинного обучения	Авторы, год
Байесовский классификатор	Lee et al., 2009 г. [51]; Brown et al., 2012 г. [52]; Topuz et al., 2017 г. [53]
Логистическая регрессия	Ibrahim et al., 2019 г. [54]; Elihimas et al., 2020 г. [55]
Древо решений	Boukenze et al., 2017 г. [56]; Aldeman et al., 2021 г. [57]; Greco et al., 2010 г. [58]
Случайный лес	Aalamifar et al., 2015 г. [59]; Salekin et al., 2016 г. [60]; Subasi et al., 2017 г. [61]; Sanchez-Pinto et al., 2018 г. [62]; Singh et al., 2019 г. [63]; Azuaje et al., 2019 г. [64]; Shaikhina et al., 2017 г. [65]; Erdim et al., 2020 г. [66]; Kocak et al., 2019 г. [67]; Senan et al., 2021 г. [68]; Scanlon et al., 2021 г. [69]; Dagliati et al., 2018 г. [70]
SVM	Leung et al., 2013 г. [71]; Chen et al., 2014 г. [72]; Wu et al., 2016 г. [73]; Charleonnan et al., 2016 г. [74]; Konieczny et al., 2021 г. [75]
ANNA	Hokamp et al., 2019 г. [76]; Aminsharifi et al., 2017 г. [44]; Niel et al., 2018 г. [77]; Konieczny et al., 2019 г. [75]
Ансамбль классификаторов	Shabaniyan et al., 2019 г. [45]; Kanda et al., 2020 г. [82]; Martínez-Martínez et al., 2014 г. [83]; Wibawa et al., 2017 г. [84]; Tran et al., 2019 г. [85]; Perrot et al., 2019 г. [29]; Hayashi et al., 2019 г. [87]; Kocak et al., 2019 г. [83]; Kunapuli et al., 2018 г. [89]; Penny-Dimri et al., 2021 г. [85]
DNN	Iakovidis et al., 2014 г. [86]; Singh et al., 2015 г. [87]; Lu et al., 2019 г. [88]; Wibawa et al., 2017 г. [80]; Agar et al., 1992 г. [89]; Aljaaf et al., 2018 г. [90]; Vanaja et al., 2018 г. [91]; Rady et al., 2019 г. [92]; Azuaje et al., 2019 г. [64]

ются до перехода к клиническим испытаниям и остаются лишь одноцентровыми ретроспективными, что снижает их внешнюю валидность. Следовательно, главный и наиболее неотложный пробел, который следует устранить как можно скорее, — это проблема публичной доступности данных.

Заключение

Приведенный анализ доступных в международной литературе исследований показывает, что применение радиомики при МКБ представляет собой быстро развивающееся направление в медицинской науке. Действительно количество доступных исследований, опубликованных за десятилетие с 2000 по 2010 г., составило всего 9, а в следующем десятилетии это число увеличилось до 35 публикаций. За текущее десятилетие уже в 2021 и 2022 гг. было опубликовано 25 отчетов, что представляет большой интерес в соответствующей области исследований.

К недостаткам многих научных публикаций по применению радиомики при МКБ можно отнести то, что в них сообщалось о результатах алгоритмов машинного обучения в диагностических или терапевтических процедурах без сравнения с текущими стандартами в соответствующих клинических областях. Более того, результаты исследований в основном были подтверждены на одних и тех же когортах пациентов, что ограничивает возможность их обобщения. Доказательность включенных исследований не превышает уровня 3. Поэтому необходимы проспективные исследования для проверки применимости их в реальном лечении МКБ.

Из общего числа исследований, включенных в настоящий обзор, очевидно, что только диагностические приложения, которые в основном связаны с лучевой диагностикой, близки к внедрению в урологическую практику, в то время как во многих работах авторы утверждали, что функция предложенной ими модели может быть дополнительно оптимизирована после вве-

дения большего количества данных. Наконец неоднородность дизайна исследований и отчетов делает результаты включенных исследований непригодными для количественного анализа и объединения данных. Также одним из ограничений радиомики, основанной на машинном обучении, является зависимость корреляция между признаками и входными данными, поскольку признаки генерируются из этого самого набора данных. Поэтому необходимы большие наборы данных для точного определения соответствующих и надежных подмножеств признаков. Еще одно ограничение — воспроизводимость и возможность передачи функций радиомики, поскольку она сильно зависит от размера, качества, последовательности, модальности, разрешения и артефактов движения при передаче изображений.

Еще одним пробелом в исследованиях является дальнейшая оптимизация процедур литотрипсии путем применения алгоритмов ИИ для корректировки интраоперационных факторов, таких как параметры лазерных генераторов, или выбора оборудования в зависимости от анатомических особенностей пациента или физических характеристик камня.

Текстурный анализ изображений камней значительно повысил точность прогнозирования типа камня в почках. Такие достижения в области технологий медицинской визуализации и машинного обучения, вероятно, будут более широко использоваться в рутинном клиническом лечении МКБ в ближайшем будущем. Тем не менее еще есть возможности для дальнейшего совершенствования алгоритмов машинного обучения в целях повышения чувствительности и специфичности методов автоматической классификации, особенно для эндоскопических изображений камней в почках. Кроме того, биохимические исследования крови и мочи также должны сочетаться с клинической информацией и медицинскими изображениями, чтобы повысить точность машинного обучения. Наконец создание сети централизованной базы для каждого типа камня, включающей демографическую и общую информацию о пациентах, параметры мочи, крови,

другие лабораторные тесты, методы лечения и их результаты, позволит разработать более надежный алгоритм машинного обучения для персонализированной медицины при МКБ.

Приведенный анализ доступных в международной литературе исследований показывает, что применение радиомики при МКБ представляет собой быстро развивающееся направление, которое все еще находится на стадии испытаний.

Дополнительная информация

Источник финансирования. Исследования выполнены, рукопись подготовлена и публикуется за счет финансирования по месту работы авторов

Конфликт интересов. Авторы данной статьи подтвердили отсутствие конфликта интересов, о котором необходимо сообщить.

Участие авторов. А.А. Пранович — написание текста статьи, литературный обзор; Г.Г. Кармазановский — написание текста статьи, литературный обзор, дизайн обзора, определение научной ценности, редактирование текста статьи; Е.С. Сирота — дизайн обзора, определение научной ценности, редактирование текста статьи; М.А. Фирсов — написание текста статьи, литературный обзор; П.А. Симонов — написание текста статьи, литературный обзор; А.И. Юнкер — написание текста статьи, литературный обзор; М.Х. Джатдоева — написание текста статьи, литературный обзор; Д.А. Хубиев — написание текста статьи, литературный обзор. Все авторы прочли и одобрили направление рукописи на публикацию.

ЛИТЕРАТУРА

- Global Burden of Disease Collaborative Network. Global Burden of Disease Study 2019 (GBD 2019) Disease and Injury Burden 1990–2019. Seattle, USA: Institute for Health Metrics and Evaluation (IHME); 2020.
- Wang Z, Zhang Y, Zhang J, et al. Recent advances on the mechanisms of kidney stone formation (Review). *Int J Mol Med*. 2021;48(2):149. doi: <https://doi.org/10.3892/ijmm.2021.4982>
- Morgan MS, Pearle MS. Medical management of renal stones. *BMJ*. 2016;352:i52. doi: <https://doi.org/10.1136/bmj.i52>
- Каприн А.Д., Аполихин О.И., Сивков А.В., и др. Заболеваемость мочекаменной болезнью в Российской Федерации с 2005 по 2020 г. // *Экспериментальная и клиническая урология*. — 2022. — Т. 15. — № 2. — С. 10–17. [Kaprin AD, Apolikhin OI, Sivkov AV, et al. Incidence of urolithiasis in the Russian Federation from 2005 to 2020. *Experimental and Clinical Urology*. 2022;15(2):10–17. (In Russ).] doi: <https://doi.org/10.29188/2222-8543-2022-15-2-10-1>
- Wagner MW, Namdar K, Biswas A, et al. Radiomics, machine learning, and artificial intelligence — what the neuroradiologist needs to know. *Neuroradiology*. 2021;63(12):1957–1967. doi: <https://doi.org/10.1007/s00234-021-02813-9>
- Пранович А.А., Исмаилов А.К., Карельская Н.А., и др. Искусственный интеллект в диагностике и лечении мочекаменной болезни // *Российский журнал телемедицины и электронного здравоохранения*. — 2022. — Т. 8. — № 1. — С. 42–57. [Pranovich AA, Ismailov AK, Karelskaya NA, et al. Artificial intelligence in the diagnosis and treatment of urolithiasis. *Russian Journal of Telemedicine and Electronic Health*. 2022;8(1):42–57. (In Russ).] doi: <https://doi.org/10.29188/2712-9217-2022-8-1-42-57>
- Gillies RJ, Kinahan PE, Hricak H. Radiomics: Images Are More than Pictures, They Are Data. *Radiology*. 2016;278(2):563–577. doi: <https://doi.org/10.1148/radiol.2015151169>
- Rizzo S, Botta F, Raimondi S, et al. Radiomics: the facts and the challenges of image analysis. *Eur Radiol Exp*. 2018;2(1):36. doi: <https://doi.org/10.1186/s41747-018-0068-z>
- Cho HH, Lee HY, Kim E, et al. Radiomics-guided deep neural networks stratify lung adenocarcinoma prognosis from CT scans. *Commun Biol*. 2021;4(1):1286. doi: <https://doi.org/10.1038/s42003-021-02814-7>
- Zhang X, Zhang Y, Zhang G, et al. Deep Learning with Radiomics for Disease Diagnosis and Treatment: Challenges and Potential. *Front Oncol*. 2022;12:773840. doi: <https://doi.org/10.3389/fonc.2022.773840>
- Avanzo M, Stancanello J, El Naqa I. Beyond imaging: The promise of radiomics. *Phys Med*. 2017;38:122–139. doi: <https://doi.org/10.1016/j.ejmp.2017.05.071>
- Keoghane S, Walmsley B, Hodgson D. The natural history of untreated renal tract calculi. *BJU Int*. 2010;105(12):1627–1629. doi: <https://doi.org/10.1111/j.1464-410X.2010.09389.x>
- Straub M, Strohmaier WL, Berg W, et al. Diagnosis and metaphylaxis of stone disease. Consensus concept of the National Working Committee on Stone Disease for the upcoming German Urolithiasis Guideline. *World J Urol*. 2005;23(5):309–323. doi: <https://doi.org/10.1007/s00345-005-0029-z>
- Ananthakrishnan L, Duan X, Xi Y, et al. Duallayer spectral detector CT: non-inferiority assessment compared to dual-source dual energy CT in discriminating uric acid from non-uric acid renal stones ex vivo. *Abdom Radiol (NY)*. 2018;43(11):3075–3081. doi: <https://doi.org/10.1007/s00261-018-1589-x>
- Liden M. A new method for predicting uric acid composition in urinary stones using routine single energy. *Urolithiasis*. 2018;46(4):325–333. doi: <https://doi.org/10.1007/s00240-017-0994-x>
- Zheng J, Yu H, Batur J, et al. A multicenter study to develop a non-invasive radiomic model to identify urinary infection stone in vivo using machine-learning. *Kidney Int*. 2021;100(4):870–880. doi: <https://doi.org/10.1016/j.kint.2021.05.031>
- Kriegshausen JS, Silva AC, Paden RG, et al. Ex vivo renal stone characterization with single-source dual-energy computed tomography: a multiparametric approach. *Acad Radiol*. 2016;23(8):969–976. doi: <https://doi.org/10.1016/j.acra.2016.03.009>
- Grosse Hokamp N, Lennartz S, Salem J, et al. Dose independent characterization of renal stones by means of dual energy computed tomography and machine learning: an ex-vivo study. *Eur Radiol*. 2020;30(3):1397–1404. doi: <https://doi.org/10.1007/s00330-019-06455-7>
- Chen HW, Chen YC, Lee JT, et al. Prediction of the uric acid component in nephrolithiasis using simple clinical information about metabolic disorder and obesity: a machine learning-based model. *Nutrients*. 2022;14(9):1829. doi: <https://doi.org/10.3390/nu14091829>
- Abraham A, Kavoussi NL, Sui W, et al. Machine learning prediction of kidney stone composition using electronic health record-derived features. *J Endourol*. 2022;36(2):243–250. doi: <https://doi.org/10.1089/end.2021.0211>
- Onal EG, Tekgul H. Assessing kidney stone composition using smartphone microscopy and deep neural networks. *BJUI Compass*. 2022;3(4):310–315. doi: <https://doi.org/10.1002/bco.2.137>
- Estrade V, Daudon M, Richard E, et al. Deep morphological recognition of kidney stones using intra-operative endoscopic digital videos. *Phys Med Biol*. 2022;67(16). doi: <https://doi.org/10.1088/1361-6560/ac8592>
- Xiang L, Jin X, Liu Y, et al. Prediction of the occurrence of calcium oxalate kidney stones based on clinical and gut

- microbiota characteristics. *World J Urol.* 2022;40(1):221–227. doi: <https://doi.org/10.1007/s00345-021-03801-7>
24. Kazemi Y, Mirroshandel SA. A novel method for predicting kidney stone type using ensemble learning. *Artif Intell Med.* 2018;84:117–126. doi: <https://doi.org/10.1016/j.artmed.2017.12.001>
 25. Sacli B, Aydinalp C, Cansiz G, et al. Microwave dielectric property based classification of renal calculi: Application of a kNN algorithm. *Comput Biol Med.* 2019;112:103366. doi: <https://doi.org/10.1016/j.compbiomed.2019.103366>
 26. Black KM, Law H, Aldoukhi A, et al. Deep learning computer vision algorithm for detecting kidney stone composition. *BJU Int.* 2020;125(6):920–924. doi: <https://doi.org/10.1111/bju.15035>
 27. Luk AC, Cleveland P, Olson L, et al. Pelvic phlebolitis: a trivial exercise for the urologist? *J Endourol.* 2017;31(4):342–347. doi: <https://doi.org/10.1089/end.2016.0861>
 28. Karius BM, Long B. Is this your stone? Distinguishing phleboliths from nephroliths on imaging in the emergency department. *J Emerg Med.* 2022;62(3):316–323. doi: <https://doi.org/10.1016/j.jemermed.2021.10.034>
 29. De Perrot T, Hofmeister J, Burgermeister S, et al. Differentiating kidney stones from phleboliths in unenhanced low-dose computed tomography using radiomics and machine learning. *Eur Radiol.* 2019;29(9):4776–4782. doi: <https://doi.org/10.1007/s00330-019-6004-7>
 30. Parakh A, Lee H, Lee JH, et al. Urinary Stone Detection on CT Images Using Deep Convolutional Neural Networks: Evaluation of Model Performance and Generalization. *Radiol Artif Intell.* 2019;1(4):e180066. doi: <https://doi.org/10.1148/ryai.2019180066>
 31. Homayounieh F, Doda Khara R, Bizzo BC, et al. Prediction of burden and management of renal calculi from whole kidney radiomics: a multicenter study. *Abdom Radiol (NY).* 2021;46(5):2097–2106. doi: <https://doi.org/10.1007/s00261-020-02865-0>
 32. Li D, Xiao C, Liu Y, et al. Deep segmentation networks for segmenting kidneys and detecting kidney stones in unenhanced abdominal CT images. *Diagnostics (Basel).* 2022;12(8):1788. doi: <https://doi.org/10.3390/diagnostics12081788>
 33. Caglayan A, Horsanali MO, Kocadurdu K, et al. Deep learning model-assisted detection of kidney stones on computed tomography. *Int Braz J Urol.* 2022;48(5):830–839. doi: <https://doi.org/10.1590/S1677-5538.IBJU.2022.0132>
 34. Långkvist M, Jendeborg J, Thunberg P, et al. Computer-aided detection of ureteral stones in thin slice computed tomography volumes using Convolutional Neural Networks. *Comput Biol Med.* 2018;97:153–160. doi: <https://doi.org/10.1016/j.compbiomed.2018.04.021>
 35. Sudharson S, Kokil P. Computer-aided diagnosis system for the classification of multi-class kidney abnormalities in the noisy ultrasound images. *Comput Methods Programs Biomed.* 2021;205:106071. doi: <https://doi.org/10.1016/j.cmpb.2021.106071>
 36. Yildirim K, Bozdag PG, Talo M, et al. Deep learning model for automated kidney stone detection using coronal CT images. *Comput Biol Med.* 2021;135:104569. doi: <https://doi.org/10.1016/j.compbiomed.2021.104569>
 37. Cui Y, Sun Z, Ma S, et al. automatic detection and scoring of kidney stones on noncontrast CT images using S.T.O.N.E. nephrolithometry: combined deep learning and thresholding methods. *Mol Imaging Biol.* 2021;23(3):436–445. doi: <https://doi.org/10.1007/s11307-020-01554-0>
 38. Elton DC, Turkbey EB, Pickhardt PJ, et al. A deep learning system for automated kidney stone detection and volumetric segmentation on noncontrast CT scans. *Med Phys.* 2022;49(4):2545–2554. doi: <https://doi.org/10.1002/mp.15518>
 39. Babajide R, Lembrikova K, Ziemba J, et al. Automated machine learning segmentation and measurement of urinary stones on CT scan. *Urology.* 2022;169:41–46. doi: <https://doi.org/10.1016/j.urology.2022.07.029>
 40. Kavoussi NL, Floyd C, Abraham A, et al. Machine learning models to predict 24 hour urinary abnormalities for kidney stone disease. *Urology.* 2022;169:52–57. doi: <https://doi.org/10.1016/j.urology.2022.07.008>
 41. Mannil M, von Spiczak J, Hermanns T, et al. Prediction of successful shock wave lithotripsy with CT: a phantom study using texture analysis. *Abdom Radio (NY).* 2018;143(6):1432–1438. doi: <https://doi.org/10.1007/s00261-017-1309-y>
 42. Mannil M, von Spiczak J, Hermanns T, et al. Three-Dimensional Texture Analysis with Machine Learning Provides Incremental Predictive Information for Successful Shock Wave Lithotripsy in Patients with Kidney Stones. *J Urol.* 2018;200(4):829–836. doi: <https://doi.org/10.1016/j.juro.2018.04.059>
 43. Oktay C, Çoraplı M, Tutuş A. The usefulness of the Hounsfield unit and stone heterogeneity variation in predicting the shockwave lithotripsy outcome. *Diagn Interv Radiol.* 2022;28(3):187–192. doi: <https://doi.org/10.5152/dir.2022.20945>
 44. Aminsharifi A, Irani D, Pooyesh S, et al. Artificial neural network system to predict the postoperative outcome of percutaneous nephrolithotomy. *J Endourol.* 2017;31(5):461–467. doi: <https://doi.org/10.1089/end.2016.0791>
 45. Shabaniyan T, Parsaei H, Aminsharifi A, et al. An artificial intelligence-based clinical decision support system for large kidney stone treatment. *Australas Phys Eng Sci Med.* 2019;42(3):771–779. doi: <https://doi.org/10.1007/s13246-019-00780-3>
 46. Hameed BMZ, Shah M, Naik N, et al. Application of artificial intelligence-based classifiers to predict the outcome measures and stone-free status following percutaneous nephrolithotomy for staghorn calculi: cross-validation of data and estimation of accuracy. *J Endourol.* 2021;35(9):1307–1313. doi: <https://doi.org/10.1089/end.2020.1136>
 47. Michaels EK, Niederberger CS, Golden RM, et al. Use of a neural network to predict stone growth after shock wave lithotripsy. *Urology.* 1998;51(2):335–338. doi: [https://doi.org/10.1016/s0090-4295\(97\)00611-0](https://doi.org/10.1016/s0090-4295(97)00611-0)
 48. Poulakis V, Dahm P, Witzsch U, et al. Prediction of lower pole stone clearance after shock wave lithotripsy using an artificial neural network. *J Urol.* 2003;169(4):1250–1256. doi: <https://doi.org/10.1097/01.ju.0000055624.65386.b9>
 49. Gomha MA, Sheir KZ, Showky S, et al. Can we improve the prediction of stone-free status after extracorporeal shock wave lithotripsy for ureteral stones? A neural network or a statistical model? *J Urol.* 2004;172(1):175–179. doi: <https://doi.org/10.1097/01.ju.0000128646.20349.27>
 50. Seckiner I, Seckiner S, Sen H, et al. A neural network — based algorithm for predicting stone — free status after ESWL therapy. *Int Braz J Urol.* 2017;43(6):1110–1114. doi: <https://doi.org/10.1590/S1677-5538.IBJU.2016.0630>
 51. Lee Y, Kim N, Cho KS, et al. Bayesian Classifier for predicting malignant renal cysts on MDCT: early clinical experience. *AJR Am J Roentgenol.* 2009;193(2):W106–111. doi: <https://doi.org/10.2214/AJR.08.1858>
 52. Brown TS, Elster EA, Stevens K, et al. Bayesian modeling of pretransplant variables accurately predicts kidney graft survival. *Am J Nephrol.* 2012;36(6):561–569. doi: <https://doi.org/10.1159/000345552>
 53. Topuz K, Zengul FD, Dag A, et al. Predicting Graft Survival among Kidney Transplant Recipients: A Bayesian Decision Support Model. *Decision Support Systems.* 2018;106:97–109. doi: <https://doi.org/10.1016/j.dss.2017.12.004>
 54. Ibrahim NE, McCarthy CP, Shrestha S, et al. A clinical, proteomics, and artificial intelligence-driven model to predict acute kidney injury in patients undergoing coronary angiography. *Clin Cardiol.* 2019;42(2):292–298. doi: <https://doi.org/10.1002/clc.23143>
 55. Elihimas Júnior UF, Couto JP, Pereira W, et al. Logistic Regression Model in a Machine Learning Application to Predict Elderly Kidney Transplant Recipients with Worse Renal Function One Year after Kidney Transplant: Elderly KTbot. *J Aging Res.* 2020;2020:7413616. doi: <https://doi.org/10.1155/2020/7413616>

56. Boukenze B, Haqiq A, Mousannif H. Predicting Chronic Kidney Failure Disease Using Data Mining Techniques. In: *Advances in Ubiquitous Networking 2*. Springer Singapore; 2017. P. 701–712. doi: https://doi.org/10.1007/978-981-10-1627-1_55
57. Aldeman NLS, de Sá Urtiga Aita KM, Machado VP, et al. Smartpath^k: a platform for teaching glomerulopathies using machine learning. *BMC Med Educ*. 2021;21(1):248. doi: <https://doi.org/10.1186/s12909-021-02680-1>
58. Greco R, Papalia T, Lofaro D, et al. Decisional trees in renal transplant follow-up. *Transplant Proc*. 2010;42(4):1134–1136. doi: <https://doi.org/10.1016/j.transproceed.2010.03.061>
59. Aalamifar F, Rivaz H, Cerrolaza JJ, et al. Classification of kidney and liver tissue using ultrasound backscatter data. In: *Medical Imaging 2015: Ultrason. Imaging Tomography*. 2015. Vol. 9419. P. 192–199. doi: <https://doi.org/10.1117/12.2082300>
60. Salekin A, Stankovic J. Detection of chronic kidney disease and selecting important predictive attributes. In: *Proceedings of the 2016 IEEE International Conference on Healthcare Informatics (ICHI)*, Chicago, IL, USA, 4–7 October 2016; P. 262–270.
61. Subasi A, Alickovic E, Kevric J. Diagnosis of Chronic Kidney Disease by Using Random Forest. IFMBE Proceedings Book Series; Springer: Berlin/Heidelberg, Germany; 2017. P. 589–594.
62. Sanchez-Pinto LN, Venable LR, Fahrenbach J, et al. Comparison of variable selection methods for clinical predictive modeling. *Int J Med Inform*. 2018;116:10–17. doi: <https://doi.org/10.1016/j.ijmedinf.2018.05.006>
63. Singh NP, Bapi RS, Vinod PK. Machine learning models to predict the progression from early to late stages of papillary renal cell carcinoma. *Comput Biol Med*. 2018;100:92–99. doi: <https://doi.org/10.1016/j.combiomed.2018.06.030>
64. Azuaje F, Kim SY, Perez Hernandez D, et al. Connecting Histopathology Imaging and Proteomics in Kidney Cancer through Machine Learning. *J Clin Med*. 2019;8(10):1535. doi: <https://doi.org/10.3390/jcm8101535>
65. Shaikhina T, Lowe D, Daga S, et al. Model Decision tree and random forest models for outcome prediction in antibody incompatible kidney transplantation. *Biomed Signal Process Control*. 2017;52:456–462. doi: <https://doi.org/10.1016/j.bspc.2017.01.012>
66. Erdim C, Yardimci AH, Bektas CT, et al. Prediction of Benign and Malignant Solid Renal Masses: Machine Learning-Based CT Texture Analysis. *Acad Radiol*. 2020;27(10):1422–1429. doi: <https://doi.org/10.1016/j.acra.2019.12.015>
67. Kocak B, Durmaz ES, Kaya OK, et al. Machine learning-based unenhanced ct texture analysis for predicting BAP1 mutation status of clear cell renal cell carcinomas. *Acta Radiol*. 2019;61(6):856–864. doi: <https://doi.org/10.1177/0284185119881742>
68. Senan EM, Al-Adhaileh MH, Alsaade FW, et al. Diagnosis of Chronic Kidney Disease Using Effective Classification Algorithms and Recursive Feature Elimination Techniques. *J Healthc Eng*. 2021;2021:1004767. doi: <https://doi.org/10.1155/2021/1004767>
69. Scanlon LA, O'hara C, Garbett A, et al. Developing an Agnostic Risk Prediction Model for Early Aki Detection in Cancer Patients. *Cancers (Basel)*. 2021;13(16):4182. doi: <https://doi.org/10.3390/cancers13164182>
70. Dagliati A, Marini S, Sacchi L, et al. Machine Learning Methods to Predict Diabetes Complications. *J Diabetes Sci Technol*. 2018;12(2):295–302. doi: <https://doi.org/10.1177/1932296817706375>
71. Leung RKK, Wang Y, Ma RCW, et al. Using a multi-staged strategy based on machine learning and mathematical modeling to predict genotype-phenotype risk patterns in diabetic kidney disease: a prospective case-control cohort analysis. *BMC Nephrol*. 2013;14:162. doi: <https://doi.org/10.1186/1471-2369-14-162>
72. Chen CJ, Pai TW, Fujita H, et al. Stage diagnosis for chronic kidney disease based on ultrasonography. In: *Proceedings of the International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)*, Xiamen, China; 2014. P. 525–530.
73. Wu B, Mukherjee S, Jain M. A new method using multiphoton imaging and morphometric analysis for differentiating chromophobe renal cell carcinoma and oncocytoma kidney tumors. In: *Multiphoton Microscopy in the Biomedical Sciences XVI*; 2016. doi: <https://doi.org/10.1117/12.2213681>
74. Charleonnann A, Fufaung T, Niyomwong T, et al. Predictive analytics for chronic kidney disease using machine learning techniques. In: *Proceedings of the Management and Innovation Technology International Conference (MITicon 2016)*. Bang-Saen, Thailand; 2016. P. MIT80–MIT83. doi: <https://doi.org/10.1109/MITICON.2016.8025242>
75. Konieczny A, Stojanowski J, Krajewska M, et al. Machine Learning in Prediction of IgA Nephropathy Outcome: A Comparative Approach. *J Pers Med*. 2021;11(4):312. doi: <https://doi.org/10.3390/jpm11040312>
76. Große Hokamp N, Lennartz S, Salem J, et al. Dose independent characterization of renal stones by means of dual energy computed tomography and machine learning: an ex-vivo study. *Eur Radiol*. 2019;30(3):1397–1404. doi: <https://doi.org/10.1007/s00330-019-06455-7>
77. Niel O, Bastard P, Boussard C, et al. Artificial intelligence outperforms experienced nephrologists to assess dry weight in pediatric patients on chronic hemodialysis. *Pediatr Nephrol*. 2018;33(10):1799–1803. doi: <https://doi.org/10.1007/s00467-018-4015-2>
78. Kanda E, Epureanu BI, Adachi T, et al. Application of explainable ensemble artificial intelligence model to categorization of hemodialysis-patient and treatment using nationwide-real-world data in Japan. *PLoS One*. 2020;15(5):e0233491. doi: <https://doi.org/10.1371/journal.pone.0233491>
79. Martinez-Martinez JM, Escandell-Montero P, Barbieri C, et al. Prediction of the hemoglobin level in hemodialysis patients using machine learning techniques. *Comput Methods Programs Biomed*. 2014;117(2):208–217. doi: <https://doi.org/10.1016/j.cmpb.2014.07.001>
80. Wibawa MS, Maysanjaya IMD, Putra IMAW. Boosted classifier and features selection for enhancing chronic kidney disease diagnose. In: *Proceedings of the International Conference on Cyber and IT Service Management (CITSM)*. Denpasar, Indonesia; 2017. doi: <https://doi.org/10.1109/CITSM.2017.8089245>
81. Tran NK, Sen S, Palmieri TL, et al. Artificial intelligence and machine learning for predicting acute kidney injury in severely burned patients: A proof of concept. *Burns*. 2019;45(6):1350–1358. doi: <https://doi.org/10.1016/j.burns.2019.03.021>
82. Hayashi Y, Nakajima K, Nakajima K. A rule extraction approach to explore the upper limit of hemoglobin during anemia treatment in patients with predialysis chronic kidney disease. *Informatics in Medicine Unlocked*. 2019;17:100262. doi: <https://doi.org/10.1016/j.imu.2019.100262>
83. Kocak B, Ates E, Durmaz ES, et al. Influence of Segmentation Margin on Machine Learning-Based High-Dimensional Quantitative CT Texture Analysis: A Reproducibility Study on Renal Clear Cell Carcinomas. *Eur Radiol*. 2019;29(9):4765–4775. doi: <https://doi.org/10.1007/s00330-019-6003-8>
84. Kunapuli G, Varghese BA, Ganapathy P, et al. A Decision-Support Tool for Renal Mass Classification. *J Digit Imaging*. 2018;31(6):929–939. doi: <https://doi.org/10.1007/s10278-018-0100-0>
85. Penny-Dimri JC, Bergmeir C, Reid CM, et al. Machine Learning Algorithms for Predicting and Risk Profiling of Cardiac Surgery-Associated Acute Kidney Injury. *Semin Thorac Cardiovasc Surg*. 2021;33(3):735–745. doi: <https://doi.org/10.1053/j.semctvs.2020.09.028>
86. Iakovidis DK, Goudas T, Smailis C, et al. Ratsnake: A Versatile Image Annotation Tool with Application to Computer-Aided Diagnosis. *ScientificWorldJournal*. 2014;2014:286856. doi: <https://doi.org/10.1155/2014/286856>
87. Singh A, Nadkarni G, Gottesman O, et al. Incorporating temporal EHR data in predictive models for risk stratification of renal

- function deterioration. *J Biomed Inform.* 2015;53:220–228. doi: <https://doi.org/10.1016/j.jbi.2014.11.005>
88. Lu Y, Jia Z, Zeng X, et al. Renal Biopsy Recommendation Based on Text Understanding. *Stud Health Technol Inform.* 2019;264:689–693. doi: <https://doi.org/10.3233/SHT1190311>
89. Agar JWM, Webb GI. Application of machine learning to a renal biopsy database. *Nephrol Dial Transplant.* 1992;7(6):472–478.
90. Aljaaf AJ, Al-Jumeily D, Haglan HM, et al. Early prediction of chronic kidney disease using machine learning supported by predictive analytics. In: *Proceedings of the 2018 IEEE Congress on Evolutionary Computation (CEC 2018)*. Rio de Janeiro, Brazil; 2018. doi: <https://doi.org/10.1109/CEC.2018.8477876>
91. Vanaja R, Mukherjee S. Novel Wrapper-Based Feature Selection for Efficient Clinical Decision Support System. *Communications in Computer and Information Science*; 2018. P. 113–129. doi: https://doi.org/10.1007/978-981-13-3582-2_9
92. Rady EHA, Anwar AS. Prediction of Kidney Disease Stages Using Data Mining Algorithms. *Informatics in Medicine Unlocked.* 2019;15:100178. doi: <https://doi.org/10.1016/j.imu.2019.100178>

КОНТАКТНАЯ ИНФОРМАЦИЯ

Пранович Александр Анатольевич, к.б.н., старший научный сотрудник [*Alexander A. Pranovich*, PhD in Biology, Senior Researcher]; **адрес:** 115093, Москва, ул. Большая Серпуховская, д. 27 **address:** 27 Bolshaya Serpukhovskaya str., 115093, Moscow, Russia]; **e-mail:** alex.pr76@mail.ru, **SPIN-код:** 1096-6331, **ORCID:** <https://orcid.org/0000-0002-6034-9269>

Кармазановский Григорий Григорьевич, д.м.н., профессор, академик РАН [*Grigory G. Karmazanovsky*, MD, PhD, Professor, Academician of the RAS]; **e-mail:** karmazanovsky@ixv.ru, **SPIN-код:** 5964-2369, **ORCID:** <https://orcid.org/0000-0002-9357-0998>

Сирота Евгений Сергеевич, д.м.н. [*Evgeniy S. Sirota*, MD, PhD]; **e-mail:** essirota@mail.ru, **SPIN-код:** 6315-7050, **ORCID:** <https://orcid.org/0000-0001-6419-0155>

Фирсов Михаил Анатольевич, к.м.н. заведующий кафедрой урологии [*Mikhail A. Firsov*, PhD]; **e-mail:** Firsma@mail.ru, **SPIN-код:** 6308-6260, **ORCID:** <https://orcid.org/0000-0002-0887-0081>

Симонов Павел Андреевич, ассистент кафедры урологии [*Pavel A. Simonov*, assistant of the Department of Urology]; **e-mail:** doctorsimonov@mail.ru, **SPIN-код:** 2339-2848, **ORCID:** <https://orcid.org/0000-0001-6741-5428>

Юнкер Александр Иосифович, соискатель кафедры урологии [*Alexander I. Junker*, applicant of the Department of Urology]; **e-mail:** junkeralex82@gmail.com, **SPIN-код:** 2339-2848, **ORCID:** <https://orcid.org/0000-0001-6741-5428>

Джатдоева Мариям Хамитовна, ординатор [*Mariam K. Dzhatdоеva*, Resident]; **e-mail:** mari.dzh0709@mail.ru, **ORCID:** <https://orcid.org/0009-0003-1589-3817>

Хубиев Динислам Абуусуфович, заведующий урологическим отделением [*Dinislam A. Khubiev*, MD, Head of the Urology Department]; **e-mail:** Dinislamx@mail.ru, **ORCID:** <https://orcid.org/0009-0002-0487-8323>