

Государственное
бюджетное учреждение
здравоохранения
«Санкт-Петербургский
клинический научно-
практический центр
специализированных видов
медицинской помощи

(онкологический)»
(Санкт-Петербург, Россия)

НОВЫЕ ТЕХНОЛОГИИ ЛУЧЕВОЙ ДИАГНОСТИКИ

В.В. Чернобривцева, А.С. Мисюрин

NEW TECHNOLOGIES IN RADIOLOGY DIAGNOSTICS

В.В. Чернобривцева

*и.о. заведующего отделения лучевой диагностики ГБУЗ «СПбКНЦСВМП(о)»,
197758, Санкт-Петербург, пос. Песочный, Ленинградская ул., д. 68А.
ORCID: 0000-0001-7037-177X.*

А.С. Мисюрин

*врач-рентгенолог отделения лучевой диагностики ГБУЗ «СПбКНЦСВМП(о)».
ORCID: 0000-0001-5082-9739.
V.V. Chernobritseva, A.S. Misyurin*

V.V. Chernobritseva

*a. head of radiology department Saint Petersburg Clinical Research and Practical Centre
for Specialized Types of Medical Care (Oncological), Saint-Petersburg, Russia,
197758, Saint-Petersburg, Pesochny-2, Leningradskaya str. 68a Lit A.
ORCID: 0000-0001-7037-177X.*

A.S. Misyurin

*radiologist in radiology department, Saint Petersburg Clinical Research and Practical Centre
for Specialized Types of Medical Care (Oncological), Saint-Petersburg, Russia.
ORCID: 0000-0001-5082-9739.*

В настоящий момент современные методы медицинской визуализации находятся в стадии разработки и внедрения программ, основанных на машинном обучении и нейросетях, призванных улучшить диагностику заболеваний, в том числе онкологических. Такие способы обработки получаемых изображений превосходят традиционные методы их оценки и снижают затраченное на это время, а также уменьшают процент ошибок в диагностике. Кроме того, более сложные программы в уже обозримом будущем смогут выступать в роли второго мнения для врача, помогая ему принять решение по выбору методик лечения больных. В настоящей работе рассмотрены некоторые аспекты, связанные с радиомикой и радиогеномикой, машинным обучением и проблемами внедрения новейших алгоритмов оценки изображения.

Ключевые слова: радиомика, радиогеномика, машинное обучение, лучевая диагностика, нейронные сети, онкология.

Today, modern medical imaging techniques are in the process of developing and implementing machine learning and neural network-based programs to improve diagnosis of several diseases, including cancer. Such methods of image processing are superior to traditional methods of image assessment and reduce the time required and diagnostic error rate. In addition, more advanced programs, in the foreseeable future, will be able to act as a second opinion for the doctor, helping him in making decisions on the choice of techniques for treating patients. In this paper some aspects related to radiomics and radiogenomics, machine learning and the challenges of implementing the latest image evaluation algorithms are discussed.

Key words: Radiomics, radiogenomics, machine learning, radiology, neural network, oncology.

Введение

В эпоху персонализированной и точной медицины мы становимся свидетелями стремительно растущей роли информационных технологий, использующих машинное обучение (МО) и количественную визуализацию, в медицине в целом и в онкологии в частности. Задачи таких технологий варьируются от компьютерной диагностики до поддержки принятия решений в лечении. В обозримом будущем это сможет изменить существующую картину терапии онкологических заболеваний.

Современные алгоритмы машинного обучения служат мощными инструментами для улучшения медицинской визуализации за счет глубокого анализа изображений и сопоставления их с возможными вариантами патологии, что приводит к сокращению человеческого труда и уменьшению числа возможных ошибок. Ожидается, что машинное обучение и искусственный интеллект позволят эффективно использовать медицинские ресурсы и сократят время, которое врач затрачивает на пациента, а также повысят качество диагностики [1–4, 23].

Новые технологии лучевой диагностики: машинное обучение

Машинным обучением в широком смысле называют алгоритмы, которые предоставляют компьютерам возможность изучать закономерности из данных или делать прогнозы на основе предыдущих примеров. Этот термин был впервые введен Артуром Сэмюэлем, одним из пионеров зарождающейся науки. А Джон Маккарти, американский специалист по информатике и автор термина «искусственный интеллект», определял машинное обучение как «Внедрение машин, которые могут выполнять задачи, характерные для человека» и рассматривал его как основную ветвь искусственного интеллекта [1, 12].

МО, как правило, предназначено для изучения аналитических закономерностей на основе данных и создания обобщений, прогнозов, на основе их представления предыдущим образцам. Эта область тесно связана с когнитивной психологией, неврологией, вычислительными и статистическими принципами, которые также нацелены на интеллектуальный анализ данных и прогнозирование производительности [15, 16].

В машинном обучении в основном признаются 3 категории: обучение с учителем, обучение без учителя и обучение с подкреплением. Контролируемое обучение с технической точки зрения направлено на поиск математической функции, которая преобразует пары входных данных в выходные метки. Неконтролируемое же обучение может работать с набором данных и без заданных меток [20, 21]. В этом случае перед компьютерным алгоритмом ставится задача самостоятельно найти внутренние структуры в интересующих данных, где они могут означать запрашиваемые по-

казатели. Контролируемое обучение обычно работает более эффективно при структурировании человеком данных, необходимых для составления базовых алгоритмов. Обучение без учителя, как правило, является более сложным, т. к. как алгоритм сам должен определять и процессировать входные данные.

Что касается третьей категории – обучения с подкреплением, – то она предназначена для воплощения программного агента (в нашем случае это может быть врач), или для выполнения действий при взаимодействии с заданной средой – например, подбора оптимальной терапии для пациента. У агента есть определенная цель (допустим, улучшение результатов лечения или диагностики), которую он должен достичь с помощью так называемой функции вознаграждения. Компания «DeepMind» приводит в качестве примера такой ситуации программу «AlphaGo», созданную по мотивам китайской игры Го, или победу агента в шахматах: это и является целью алгоритма обучения с подкреплением [15]. Стоит отметить, что обучение с подкреплением является современным улучшением классических статистических схем принятия решений, известных как марковские процессы принятия решений. Первоначально они появились в 1950-х годах, а в настоящее время получили широкое распространение благодаря передовым вычислительным технологиям.

Итак, машинное обучение – это междисциплинарная область искусственного интеллекта, опирающаяся на достижения в области компьютерных наук, нейронауки, психологии и статистики для разработки компьютерных алгоритмов, которые могут изучать, анализировать массивы данных и решать поставленные задачи [7, 8]. В настоящее время применение машинного обучения широко распространено в самых разнообразных областях (например, в банковском деле, спорте, политике и рекламе), т.к. оно обеспечивает надежное руководство для принятия решений и сокращает ручной труд. Подобласть машинного обучения, называемая глубоким обучением (deep learning), позволяет абстрактно представлять данные с помощью глубоких нейронных сетей (также известных как многослойные нейронные сети). Оно уверенно продемонстрировало свой потенциал в имитации человеческого познания и бросило вызов интеллектуальным способностям человека – от видео или настольных игр до медицины [9–13].

В области медицины компании, занимающиеся информационными технологиями, активно разрабатывают и ищут приложения для своих инструментов МО. Например, «Google DeepMind» выпустила мобильные приложения для диагностики заболеваний глаз, травм почек и управления электронными картами пациентов для их правильной, своевременной и эффективной маршрутизации. В области онкологии растет интерес к применению машинного обучения для диагностики, прогнозирования и лечения. Так,

система «IBM Watson for Oncology» (WFO) продемонстрировала свою эффективность в составлении рекомендаций по лечению конкретных онкологических больных. При раке молочной железы WFO смогла изучить большое количество информации из медицинских журналов, учебников и руководств по лечению в Мемориальном онкологическом центре имени Слоана-Кеттеринга (MSKCC) путем обработки и анализа языка, чтобы определить статьи, которые соответствуют характеристикам конкретных пациентов [5]. WFO может дополнительно усовершенствовать свой аналитический процесс в соответствии с отзывами экспертов. Наконец, система может предоставить рекомендации по планированию лечения (хирургия, химиотерапия, иммунотерапия, лучевая терапия) и альтернативные варианты в рамках каждого плана лечения (например, лекарства или дозы) для конкретного пациента. Система была протестирована в онкологическом центре Манипала, показав высокую степень соответствия (93%) с междисциплинарной комиссией по опухолям.

Алгоритмы, основанные на глубоком обучении, – такие как свёрточная нейронная сеть (convolutional neural network, CNN), – применялись для визуальной диагностики самых различных видов онкологии. Они продемонстрировали высокую точность, сравнимую или превосходящую таковую у специалистов-людей. Например, CNN смогла различить наиболее распространенные и самые опасные типы рака кожи, изучив набор данных, состоящий из 12 940 изображений с подтвержденными клиническими случаями и превзойдя двух дерматологов в их повторной оценке на предмет патологии [6]. В соревновании по разработке автоматизированных решений для обнаружения метастазов в лимфатических узлах при раке молочной железы по изображениям патологии наиболее эффективный алгоритм также был основан на CNN с глубоким обучением. При этом были достигнуты лучшие диагностические результаты, чем у группы из 11 патологоанатомов при симулированном упражнении, предназначенном для имитации рутинного клинического рабочего процесса. Помимо высокой точности прогнозов, предлагаемых алгоритмами МО, они также обладают высокой эффективностью и могут быть экономически выгодными. Например, хорошо обученная на предыдущих клинических примерах CNN может поставить точный диагноз за доли секунды в любое время, предлагая возможность универсального доступа к диагностической помощи в любом месте и в любое время [15, 16].

В будущем системы когнитивного обучения (такие как WFO) потенциально могут предложить врачам необходимые инструменты для адаптации своего лечения к конкретному пациенту на основе синтезированных знаний с помощью алгоритмов из существующей литературы и интерактивного обучения от экспертов в области клинической онкологии.

Из-за сложных технических достижений и огромного роста генетических и клинических данных практикующим врачам становится все труднее быть в курсе всех новых научных открытий [12, 13]. Системы на основе машинного обучения могут получать такие знания из большого объема неструктурированных или структурированных наборов данных, объединять и эффективно представлять такие синтезированные знания практикующим врачам в качестве второго мнения, чтобы помочь и поддержать их в принятии решений и улучшить тактику лечения онкологических больных.

Новые технологии лучевой диагностики: глубокое обучение

В последнее время такая интересная и мощная ветвь машинного обучения, как глубокое обучение, демонстрирует огромные успехи в решении задач распознавания образов и компьютерного зрения по сравнению с классическими методами машинного обучения. Эти алгоритмы обучения, как правило, основаны на архитектуре сложных нейросетей. Эмпирически доказано, что глубокое обучение способно эффективно учиться на сложных задачах, что связано с его неотъемлемым свойством, называемым «универсальной аппроксимацией». Некоторые узкоспециализированные глубокие нейросети разрабатываются для выполнения различных задач (как, например, уже упоминавшаяся выше CNN), для распознавания и классификации изображений и рекуррентных нейронных сетей (recurrent neural network, RNN). Эти последние хорошо подходят для последовательного обучения текстовым подписям к изображениям [18–20, 23].

Перечисленные функции нейросетей и программ на их основе делают их естественным образом подходящими для поддержки принятия решений за счет включения объективной информации о пациенте и его обследованиях, для планирования лечения и адаптации терапии. Добиться автоматической поддержки принятия решений в лучевой терапии можно и с помощью обучения с подкреплением, при котором желаемые преимущества достигаются программным агентом. Это тот же принцип, который привел вышеупомянутую программу AlphaGo к победе в китайской игре Го. Таким образом, глубокое обучение может оптимизировать прогнозирование результатов и определять оптимальные стратегии точного лечения в онкологии [13, 15].

Новые технологии лучевой диагностики: обработка изображений в онкологии

Медицинская визуализация широко применяется в клинической практике. В последнее время она продемонстрировала еще больший потенциал и полезность благодаря недавним прорывам в сфере машинного обучения [5–8].

Существует 2 основных типа получения изображений: 1 – анатомические изображения, включающие обычные рентгеновские снимки, ультразвуковые исследования, компьютерную томографию (КТ) и магнитно-резонансную томографию (МРТ) и т.д.; 2 – функциональная (молекулярная) визуализация, включающая позитронно-эмиссионную томографию (ПЭТ), однофотонную эмиссионную компьютерную томографию (ОФЭКТ) и диффузионно-взвешенную МРТ и др. Для того, чтобы объединить преимущества анатомического разрешения и функциональной информации о тканях, были разработаны мультимодальные методы визуализации, такие как ОФЭКТ/КТ, ПЭТ/КТ или ПЭТ/МРТ. Благодаря всем этим методам изображения могут предоставить ценные данные, закодированные с индивидуальной информацией пациента о типе его ЗНО и сопутствующей патологии, которые могут быть извлечены, чтобы помочь в диагностике и прогнозировании возможных исходов лечения [9, 12–14].

В результате развития передовых методов распознавания образов и инструментов статистического обучения цифровые медицинские изображения теперь можно преобразовывать в пригодные для обработки многомерные данные посредством высокопроизводительного извлечения количественных признаков. Это показало большой потенциал прецизионной медицины в онкологии, а именно, в радиомике.

Новые технологии лучевой диагностики: радиомика и радиогеномика.

Вновь подчеркнем, что медицинская визуализация играет важную роль в онкологической практике при диагностике, определении стадии опухоли, руководстве лечением, оценке результатов лечения и последующем наблюдении за пациентами. Будучи неинвазивным методом, изображения могут предоставить как пространственную, так и временную информацию об опухоли. Извлечение количественных характеристик из медицинских изображений вместе с последующим связыванием этих характеристик с биологическими конечными точками и клиническими результатами называется радиомикой. Корень «radio-» происходит от радиологии, которая относится к рентгенологическим изображениям (КТ, МРТ и ПЭТ), а «-omics» означает технологии, нацеленные на предоставление коллективных и количественных характеристик всей системы и изучение механизмов, лежащих в их основе. Данные методы исследования широко используются в биологии, например, при изучении генов (геномика), белков (протеомика) и метаболитов (метаболомика). Предназначение радиомики – анализ и понимание медицинских изображений. Непосредственной целью радиомики является использование цифровых данных, хранящихся в этих изображениях, для разработки диагностических, прогностических или радиоло-

гических моделей, которые в состоянии определить биологические и клинические процессы, лежащие в основе конкретной патологии, а затем помочь разработать и оптимизировать индивидуальную программу лечения. Ядром радиомики является извлечение количественных признаков, с помощью которых мы можем применять все продвинутые алгоритмы машинного обучения и строить модели для связи между изображениями и биологическими и клиническими конечными точками. Центральная гипотеза анализа методом радиомики заключается в том, что особенности визуализации способны фиксировать четкие фенотипические различия, такие как генетические и протеомные паттерны или другие клинические результаты, чтобы специалисты могли сделать вывод об этих конечных результатах. Исследования последних лет подтвердили потенциал радиометрических признаков для анализа свойств конкретных опухолей. Главным компонентом всех приведенных выше примеров является возможность получения или вывода скрытой информации из пикселей или вокселей цифровых изображений. Имеются два основных процесса, которые помогают связать необработанные изображения с конечными точками: 1 – извлечение признаков; 2 – классификация или регрессия с использованием извлеченных признаков.

Существует два основных способа извлечения полезных признаков: 1 – методы ручной работы или прямое использование существующих радиомикроскопических сигнатур; 2 – автоматическое обучение представлению изображений глубокими нейронными сетями (например, CNN) [5, 6, 14].

Многомерные характеристики, получаемые в результате обработки изображений высокого разрешения, также подразделяются на два типа: семантические и агностические. Семантические характеристики представляют собой главным образом морфологические особенности, описывающие размеры, форму, локализацию, кровоснабжение, структуру, некротические изменения очага. Агностические характеристики содержат математически-вычисленные количественные особенности, которые в свою очередь могут быть в дальнейшем разделены на три группы: 1 – статистические результаты первого порядка, описывающие значения внутри одного вокселя, 2 – второго порядка, описывающие соотношения между вокселями, и 3 – более высоких порядков – дополнительные параметры изображения с применением различных фильтров. Технологии глубокого обучения также могут быть использованы для автоматизированного экстрагирования описательных характеристик высокого порядка очагов опухоли. Добытые таким образом радиомные сигнатуры могут затем использоваться для множества целей, таких как классификация опухоли, прогнозирование выживаемости и ответа на лечение [14]. Исследования, обнаружившие взаимосвязь

между радиомикой и молекулярно-генетическими параметрами, как раз и попадают под определение радиогеномики. Они ставят целью обнаружить суррогатные паттерны для геномных сигнатур, а также для разработки биомаркеров, эффективно использующих различные типы данных для характеристики заболевания. Эти многомерные биомаркеры могут быть использованы впоследствии для предсказания выживаемости и ответа на лечение, играя важнейшую роль в персонализации терапевтических алгоритмов.

Новые технологии лучевой диагностики: выбор функций, построение моделей и проверка

В задачах визуализации для радиационной онкологии, таких как сегментация или оконтуривание опухоли, обучение программы со специалистом наиболее эффективно. Достаточно сложно найти стандартизируемые, повторяемые и воспроизводимые для подгонки модели с большим количеством характеристик, извлеченных из медицинских изображений, особенно когда размер выборки пациентов намного меньше, чем характеристики данных. В этих ситуациях переобучение и высокая дисперсия являются основными трудностями из-за так называемой «проблемы большой размерности» [10, 11]. Один из методов состоит в том, чтобы уменьшить размер входных данных с помощью выбора признаков, а именно выбора подмножества переменных, которые являются показательными для целей классификации. Такой выбор данных может быть полезен, когда признаки являются избыточными или иногда нерелевантными по отношению к задаче классификации [13].

Выполняя выбор признаков, пространство переменных уменьшается, что помогает построить более узкоспециализированную модель прогнозирования. Кроме того, снижается стоимость вычислений и хранения данных. Также для интерпретации и понимания механизма, лежащего в основе данных, выбранным структурам необходимо отражать цель классификации. Распространенными методами выбора признаков являются методы фильтрации и методы-оболочки, где первые выбирают переменные, ранжируя их с помощью коэффициентов корреляции, а вторые ищут оптимальный набор признаков, оценивая их «полезность» по отношению к заданному параметру [18–20].

Доступность данных в количественном и качественном отношении – один из ключевых факторов повышения производительности машинного обучения. До формирования универсального искусственного интеллекта компьютеры вряд ли могут понять сложные физические законы на основании всего лишь нескольких примеров, а способны разве что выводить эмпирические отношения на основе множественных наблюдений с помощью алгоритмов статистического вывода. В области медицины, где наборы данных, как правило, небольшие, уникальные,

редко воспроизводимые, а иногда и искаженные, полная оптимизация машинного обучения может оказаться проблемой.

Новые технологии лучевой диагностики: проблемы на пути к модернизации

К новым технологиям в медицине традиционно предъявляются высокие требования, исходящие из большой степени ответственности перед здоровьем пациентов. Так или иначе, как и для любых новинок, неизбежна стадия апробации, выявление и устранение «детских болезней» самих программ, а также оптимизация методики внедрения и работы с подобного рода инновациями. Так, с клинической точки зрения все еще может быть неясен выбор функций или параметров, подходящих для решения конкретной диагностической или терапевтической задачи с использованием алгоритма МО (например, параметры, заданные вручную, или функции, полученные с помощью машинного обучения) [18]. На примере выявления метастазов рака молочной железы исследователи обнаружили, что распознавание системами глубокого обучения и работа патологов-людей взаимодополняют друг друга. Система помогла снизить частоту ошибок патологов с более чем 3% до менее 1%. Таким образом, на текущем этапе системы глубокого обучения больше подходят в качестве второго мнения, для помощи и поддержки в принятии решений или проверки качества, а не в качестве автономной системы. Вот примеры других подобных проблем.

Одной из важнейших проблем применения искусственного интеллекта в медицине можно назвать риск ошибочного выставления диагноза. Ученые предупреждают, что использование методов реконструкции и анализа снимков с помощью искусственного интеллекта для постановки диагноза и определения лечения с некоторой долей вероятности может нанести вред пациентам [19]. По их словам, даже мелкие погрешности «на входе» могут привести к принципиальным расхождениям в диагнозе.

Опасения оправданы: опытный врач, оценив снимок, сможет отличить дефект изображения от новообразования или попросит сделать диагностику еще раз. Искусственный же интеллект и программы с машинным обучением используют имеющуюся информацию и ставят предполагаемый диагноз, исходя из предоставленных данных, тем самым, возможно, сильно повлияв на дальнейшую диагностику и выбор методов лечения.

Неточности во входных данных могут привести к самым неприятным последствиям в виде сбоя алгоритма поиска патологического очага или даже его пропуска, а также к неверной интерпретации полученных результатов. Проблема может возникнуть как на этапе обучения компьютера, так и при его эксплуатации медицинским учреждением. Малейшее искажение

на снимке, которое может быть вызвано простым движением (дыханием) пациента, сильно ухудшает результаты распознавания изображений [6, 22].

Общество всегда приветствует использование новых технологий в нашей жизни, но рисковать и первыми внедрять их в свои рабочие процессы готовы не все. Мало кто готов взять на себя ответственность задействовать новые инструменты, которые еще недостаточно изучены персоналом, а также еще не выяснены их эффективность и процент ошибок.

Логика, лежащая в основе сделанных выводов программ с МО и нейросетей, непонятна большинству врачей или некомпетентным в этой области специалистам. Это приводит к неуверенности в корректности достигнутого результата. То, каким образом ИИ пришел к тому или иному выводу, является существенной информацией, важной для составления плана лечения. И если этого не понимать – будет сохраняться скепсис по отношению к результатам, достигнутым новыми способами [12–16].

Данные о состоянии здоровья пациентов – это персональные данные, приватная информация – крайне чувствительная сфера. Для их защиты необходимо создать надлежащие механизмы, на которые, вероятно, придется затратить значительные средства и силы.

Сбор данных о пациентах регулируется рядом законов, включая ФЗ-152. Обмен данными между различными базами данных для анализа с помощью алгоритмов ИИ представляет собой проблему с точки зрения соответствия требованиям действующего законодательства. Помимо этого, для нормальной работы требуется мощная вычислительная инфраструктура. В частности, высокопроизводительные графические процессоры [23].

Заключение

За последние несколько лет в широком спектре областей онкологии наблюдается огромный рост числа программ, основанных на машинном обучении: это и создание прогностических моделей диагностики заболеваний или ответа на лечение, и автоматизация рабочего процесса, и поддержка принятия решений. По мере продолжения развития методов и приемов машинного обучения можно ожидать, что его роль в области лечения онкологических заболеваний будет возрастать. Возможно, машинное обучение изменит то, как врачи принимают клинические решения, и какое лечение получают пациенты, да и диагностика станет быстрее и точнее. Однако прежде чем возвестить наступление эры машинного обучения, нужно также вспомнить о характеристиках и ограничениях этой технологии. Методы программ МО требуют больших объемов данных для их обучения и проверки, а это порождает проблемы с обработкой информации и ее конфиденциальностью. Знания, основанные на многочисленных статьях, клинических случаях и наблюдениях, должны быть включены и неотъемлемо внедрены в современные архитектуры МО. С помощью самых современных алгоритмов МО информативность изображений обладает потенциалом для обеспечения более точной медицинской помощи больным онкологического профиля, а также для выявления биологических закономерностей, лежащих в основе патологических процессов. Применение алгоритмов машинного обучения в медицинской сфере является многообещающим, однако остается решить еще много проблем, прежде чем они смогут реализовать свой потенциал в повседневной клинической практике в полной мере.

Список литературы

1. Tseng H.H., et al. Machine learning and imaging informatics in oncology // *Oncology*. – 2020. – Vol. 98, № 6. – P. 344–362.
2. Rodriguez H., Zenklusen J. C., Staudt L. M., Doroshow J.H., Lowy D.R. The next horizon in precision oncology: Proteogenomics to inform cancer diagnosis and treatment // *Cell*. – 2021. – Vol. 184, № 7. – P. 1661–1670.
3. Huang S.H., Pan Y.C. Automated visual inspection in the semiconductor industry: A survey // *Computers in industry*. – 2015. – Vol. 66. – P. 1–10.
4. Yesbaswini S. Voice Recognition and Human Child Robot Interaction. Doctoral dissertation, Southeast Missouri State University, 2020.
5. Kooti F., et al. Analyzing Uber's ride-sharing economy // *Proceedings of the 26th International Conference on World Wide Web Companion*. – 2017. – P. 574–582.
6. Somashekhar S.P., et al. Watson for Oncology and breast cancer treatment recommendations: agreement with an expert multidisciplinary tumor board // *Annals of Oncology*. – 2018. – Vol. 29, № 2. – P. 418–423.
7. Esteva A., et al. Dermatologist-level classification of skin cancer with deep neural networks // *Nature*. – 2017. – Vol. 542, № 7639. – P. 115–118.
8. Cohen J.D., et al. Detection and localization of surgically resectable cancers with a multi-analyte blood test // *Science*. – 2018. – Vol. 359, № 6378. – P. 926–930.
9. El Naqa I. (ed.). A guide to outcome modeling in radiotherapy and oncology: listening to the data. – CRC Press, 2018.

10. Kumar V., et al. Radiomics: the process and the challenges // Magnetic resonance imaging. – 2012. – Vol. 30, № 9. – P. 1234–1248.
11. Scapicchio C., et al. A deep look into radiomics // La radiologia medica. – 2021. – Vol. 126, № 10. – P. 1296–1311.
12. Nardone V., et al. Delta radiomics: A systematic review // La radiologia medica. – 2021. – P. 1–13.
13. Field M., et al. Machine learning applications in radiation oncology // Physics and Imaging in Radiation Oncology. – 2021. – Vol. 19. – P. 13–24.
14. Singh G., et al. Radiomics and radiogenomics in gliomas: a contemporary update // British Journal of Cancer. – 2021. – Vol. 125, № 5. – P. 641–657.
15. Ferro M., et al. Prostate Cancer Radiogenomics–From Imaging to Molecular Characterization // International Journal of Molecular Sciences. – 2021. – Vol. 22, № 18. – P. 9971.
16. Silver D., et al. Mastering the game of Go with deep neural networks and tree search // Nature. – 2016. – Vol. 529, № 7587. – P. 484–489.
17. Pot M., Kieusseyan N., Prainsack B. Not all biases are bad: equitable and inequitable biases in machine learning and radiology // Insights into imaging. – 2021. – Vol. 12, № 1. – P. 1–10.
18. Mongan J., et al. RSNA-MICCAI panel discussion: Machine learning for radiology from challenges to clinical applications // Radiology: Artificial Intelligence. – 2021. – Vol. 3, № 5. – P. e210118.
19. Zhang K., et al. Mitigating bias in radiology machine learning: 2. Model development // Radiology: Artificial Intelligence. – 2022. – Vol. 4, № 5. – P. e220010.
20. Gharaibeh M., et al. Radiology imaging scans for early diagnosis of kidney tumors: a review of data analytics-based machine learning and deep learning approaches // Big Data and Cognitive Computing. – 2022. – Vol. 6, № 1. – P. 29.
21. Olthof A.W., et al. Machine learning based natural language processing of radiology reports in orthopaedic trauma // Computer methods and programs in biomedicine. – 2021. – Vol. 208. – P. 106304.
22. López-Úbeda P., et al. Automatic medical protocol classification using machine learning approaches // Computer Methods and Programs in Biomedicine. – 2021. – Vol. 200. – P. 105939.
23. Granata V., et al. Radiomics in hepatic metastasis by colorectal cancer // Infectious Agents and Cancer. – 2021. – Vol. 16, № 1. – P. 1–9.
24. Маслов Н.Е., Труфанов Г.Е., Ефимцев А.Ю. Некоторые аспекты радиомики и радиогеномики глиобластом: что лежит за пределами изображения? // Трансляционная медицина. – 2022. – Т. 9. – № 2. – С. 70–80.

References

1. Tseng H.H., et al. Machine learning and imaging informatics in oncology. Oncology. 2020; 98(6): 344–362.
2. Rodriguez H., Zenklusen J. C., Staudt L. M., Doroshow J.H., Lowy D.R. The next horizon in precision oncology: Proteogenomics to inform cancer diagnosis and treatment. Cell. 2021; 184(7): 1661–1670. Doi: 10.1016/j.cell.2021.02.055.
3. Huang S.H., Pan Y.C. Automated visual inspection in the semiconductor industry: A survey. Computers in industry. 2015; 66: 1–10.
4. Yesbaswini S. Voice Recognition and Human Child Robot Interaction. Doctoral dissertation, Southeast Missouri State University, 2020.
5. Kooti F., et al. Analyzing Uber's ride-sharing economy. Proceedings of the 26th International Conference on World Wide Web Companion. 2017: 574–582.
6. Somashekhar S.P., et al. Watson for Oncology and breast cancer treatment recommendations: agreement with an expert multidisciplinary tumor board. Annals of Oncology. 2018; 29(2): 418–423.
7. Esteva A., et al. Dermatologist-level classification of skin cancer with deep neural networks. Nature. 2017; 542(7639): 115–118.
8. Cohen J.D., et al. Detection and localization of surgically resectable cancers with a multi-analyte blood test. Science. 2018; 359(6378): 926–930.
9. El Naqal I. (ed.). A guide to outcome modeling in radiotherapy and oncology: listening to the data. CRC Press, 2018.
10. Kumar V., et al. Radiomics: the process and the challenges. Magnetic resonance imaging. 2012; 30(9): 1234–1248.
11. Scapicchio C., et al. A deep look into radiomics. La radiologia medica. 2021; 126(10): 1296–1311.
12. Nardone V., et al. Delta radiomics: A systematic review. La radiologia medica. 2021; 1–13.
13. Field M., et al. Machine learning applications in radiation oncology. Physics and Imaging in Radiation Oncology. 2021; 19: 13–24.
14. Singh G., et al. Radiomics and radiogenomics in gliomas: a contemporary update. British Journal of Cancer. 2021; 125(5): 641–657.
15. Ferro M., et al. Prostate Cancer Radiogenomics–From Imaging to Molecular Characterization. International Journal of Molecular Sciences. 2021; 22(18): 9971.
16. Silver D., et al. Mastering the game of Go with deep neural networks and tree search. Nature. 2016; 529(7587): 484–489.
17. Pot M., Kieusseyan N., Prainsack B. Not all biases are bad: equitable and inequitable biases in machine learning and radiology. Insights into imaging. 2021; 12(1): 1–10.
18. Mongan J., et al. RSNA-MICCAI panel discussion: Machine learning for radiology from challenges to clinical applications. Radiology: Artificial Intelligence. 2021; 3(5): e210118.

19. Zhang K., et al. Mitigating bias in radiology machine learning: 2. Model development. *Radiology: Artificial Intelligence*. 2022; 4(5): e220010.
20. Gbaraibeh M., et al. Radiology imaging scans for early diagnosis of kidney tumors: a review of data analytics-based machine learning and deep learning approaches. *Big Data and Cognitive Computing*. 2022; 6(1): 29.
21. Olthof A.W., et al. Machine learning based natural language processing of radiology reports in orthopaedic trauma. *Computer methods and programs in biomedicine*. 2021; 208: 106304.
22. López-Úbeda P., et al. Automatic medical protocol classification using machine learning approaches. *Computer Methods and Programs in Biomedicine*. 2021; 200: 105939.
23. Granata V., et al. Radiomics in hepatic metastasis by colorectal cancer. *Infectious Agents and Cancer*. 2021; 16(1): 1-9.
24. [Maslov N.E., et al. Certain aspects of radiomics and radiogenomics in glioblastoma: what the images hide? *Translational Medicine*. 2022; 9(2): 70-80. (In Russ)]