

ГАРАНИН А.А.,

к.м.н., ФГБОУ ВО «СамГМУ» Минздрава России, г. Самара, Россия;
e-mail: sameagle@yandex.ru

РУБАНЕНКО О.А.,

д.м.н., ФГБОУ ВО «СамГМУ» Минздрава России, г. Самара, Россия;
e-mail: olesya.rubanenko@gmail.com

ТРУСОВ Ю.А.,

ФГБОУ ВО «СамГМУ» Минздрава России, г. Самара, Россия;
e-mail: yu.a.trusov@samsmu.ru

СЕНЮШКИН Д.В.,

ФГБОУ ВО «СамГМУ» Минздрава России, г. Самара, Россия;
e-mail: d.v.senushkin@samsmu.ru

КОЛСАНОВ А.В.,

д.м.н., профессор, член-корреспондент РАН, ФГБОУ ВО «СамГМУ» Минздрава России,
г. Самара, Россия; e-mail: a.v.kolsanov@samsmu.ru

АСПЕКТЫ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ СКРИНИНГА И ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ: НАРРАТИВНЫЙ ОБЗОР

DOI: 10.25881/18110193_2026_1_22

Аннотация. Актуальность. Активное внедрение искусственного интеллекта (ИИ) в сферу здравоохранения существенно повышает эффективность ранней диагностики различных заболеваний. Среди перспективных направлений внедрения ИИ выделяются методы диагностики, основанные на анализе голоса, дистанционном мониторинге кровообращения методом фотоплетизмографии, отслеживании особенностей движения глаз, а также использование умных устройств для непрерывного мониторинга здоровья. Важнейшей задачей является разработка интегрированных систем комплексного медицинского скрининга.

Цель. Оценка литературных данных и анализ результатов применения искусственного интеллекта для раннего выявления заболеваний.

Материал и методы. Проведен поиск в базах данных PubMed (Medline), Google Scholar, eLibrary, Web of Science, Scopus, CyberLeninka работ на английском и русском языках, в которых осуществлялся скрининг заболеваний, по ключевым терминам «screening», «diagnostics», «artificial intelligence», «machine learning», «disease», «скрининг», «диагностика», «искусственный интеллект», «заболевание», «машинное обучение», «глубокое обучение». Включение исследований (2015–2025 гг.) основано на независимой оценке тремя исследователями, которые пришли к единому мнению.

Результаты. Для данного обзора в процессе отбора соответствующих исследований включена 31 работа, отвечающая критериям поиска, из 1141 публикаций.

Заключение. Скрининг и диагностика заболеваний с применением ИИ предоставляет существенную информацию о состоянии пациента, снижая риск человеческого фактора и пропуска ранних признаков заболевания.

Ключевые слова: скрининг, заболевание, искусственный интеллект, машинное обучение.

Для цитирования: Гаранин А.А., Рубаненко О.А., Трусов Ю.А., Сенюшкин Д.В., Колсанов А.В. Аспекты применения искусственного интеллекта для скрининга и диагностики заболеваний: нарративный обзор. Врач и информационные технологии. 2026; 1: 22-37. DOI: 10.25881/18110193_2026_1_22.

GARANIN A.A.,

PhD, Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: sameagle@yandex.ru

RUBANENKO O.A.,

DSc, Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: olesya.rubanenko@gmail.com

TRUSOV YU.A.,

Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: yu.a.trusov@samsmu.ru

SENYUSHKIN D.V.,

Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: d.v.senushkin@samsmu.ru

KOLSANOV A.V.,

DSc, Professor, Corresponding Member of the Russian Academy of Sciences, Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: a.v.kolsanov@samsmu.ru

ASPECTS OF THE USE OF ARTIFICIAL INTELLIGENCE FOR DISEASE SCREENING AND DIAGNOSIS: A NARRATIVE REVIEW

DOI: 10.25881/18110193_2026_1_22

Abstract. *Background.* The active implementation of artificial intelligence (AI) in healthcare significantly improves the effectiveness of early diagnosis of various diseases. Promising areas for AI implementation include diagnostic methods based on voice analysis, remote blood flow monitoring using photoplethysmography, eye movement tracking, and the use of smart devices for continuous health monitoring. A key objective is the development of integrated systems for comprehensive medical screening.

Aim. To evaluate the literature and analyze the results of artificial intelligence implementation for the early detection of diseases.

Materials and methods. A search was conducted in the databases PubMed (Medline), Google Scholar, eLibrary, Web of Science, Scopus, CyberLeninka for English- and Russian-language publications. We used the keywords "screening," "diagnostics," "artificial intelligence," "machine learning," "disease," "screening," "diagnostics," "artificial intelligence," "disease," "machine learning," and "deep learning." Studies from 2015 to 2025 were included based on independent review by three researchers who reached a consensus.

Results. Thirty-one papers from 1,141 publications that met the search criteria were included for this review.

Conclusions. AI-based disease screening and diagnosis provides valuable information about a patient's condition, reducing the risk of human error and missing early signs of disease.

Keywords: screening, disease, artificial intelligence, machine learning.

For citation: Garanin A.A., Rubanenko O.A., Trusov Yu.A., Senyushkin D.V., Kolsanov A.V. Aspects of the use of artificial intelligence for disease screening and diagnosis: a narrative review. Medical doctor and information technology. 2026; 1: 22-37. DOI: 10.25881/18110193_2026_1_22.

ВВЕДЕНИЕ

Искусственный интеллект (ИИ) активно внедряется в медицинскую практику, помогая выявлять заболевания на ранних стадиях. Основные направления применения включают онкологический скрининг (анализ маммограмм с точностью выше специалиста-рентгенолога, диагностика рака кожи по фотографиям, выявление онкологических заболеваний на снимках магнитно-резонансной томографии (МРТ), компьютерной томографии (КТ)), кардиологическую диагностику (оценка рисков сердечно-сосудистых заболеваний (ССЗ) по ЭКГ, прогнозирование инсультов, анализ состояния сосудов по снимкам сетчатки), офтальмологический скрининг (выявление диабетической ретинопатии, диагностика заболеваний сетчатки, оценка состояния глазного дна) [1–5]. Практические решения для своевременного выявления заболеваний основаны на широко известных приложениях и платформах, обученных с использованием методов машинного обучения: ПроРодинки (случаи скрининга новообразований кожи) [6], SkinVision (система диагностики рака кожи по фотографиям с телефона) [7], IDx-DR (программа для анализа сетчатки глаза) [8], Ezra (ИИ-система для анализа МРТ-снимков) [9, 10], KardiaMobile (решение для анализа ЭКГ) [11]. Современные стоматологические клиники используют ИИ в клинической практике. К примеру, применение интраоральных камер, интегрированных с ИИ, даёт возможность мгновенно оценить состояние слизистой оболочки ротовой полости. Алгоритмы на базе ИИ способны самостоятельно классифицировать пациентов по степени риска, направляя их на углублённую диагностику. Совместное применение цифровых стоматологических изображений и КТ совместно с технологиями ИИ позволяет обнаруживать не только злокачественные новообразования, но также и ранние признаки онкологии [12–14]. Следовательно, внедрение ИИ способствует высокой точности и скорости анализа (ИИ может обрабатывать изображения за доли секунды, выявляя изменения, которые могут быть незаметны глазу опытного специалиста), снижению числа пропущенных диагнозов (за счёт автоматического скрининга снижается риск человеческого фактора и пропуска ранних признаков заболевания), экономии времени врача и пациента (быстрый анализ позволяет быстрее

принять решение о дальнейшем обследовании или лечении), доступности в удалённых регионах (ИИ можно интегрировать в телемедицинские платформы, что особенно важно для жителей отдалённых населённых пунктов, где нет возможности получения консультации специалистами узкого профиля) [15–16]. Преимущества использования ИИ обусловлены повышением точности диагностики, ускорением процесса анализа медицинских изображений, снижением нагрузки на врачей, возможностью раннего выявления заболеваний, персонализацией скрининговых программ. Перспективные направления для применения ИИ в практике врача — это диагностика состояния по голосу, дистанционной фотоплетизмографии, анализ движений глаз, мониторинг состояния через носимые устройства, создание комплексных систем скрининга [17–19].

Однако применение ИИ характеризуется рядом ограничений (зависимость от качества обучающих данных, вопросы интерпретируемости алгоритмов, правовые и этические аспекты) [48, 50]. Ошибочные исходные данные приводят к неправильному диагнозу. Например, при распознавании изображений некоторые детали (например, опухоль) могут быть пропущены или, наоборот, добавлены. Нейросети не дают ответ на вопрос, почему был получен тот или иной результат. Логика, лежащая в основе сделанных выводов, непонятна, и это приводит к неуверенности в корректности достигнутого результата. Кроме того, неясно, кто несёт ответственность за ошибки алгоритма — врач или разработчик.

Использование ИИ в скрининге позволяет значительно повысить эффективность ранней диагностики заболеваний и снизить риски развития серьезных осложнений. Однако для достижения максимального эффекта требуется комплексный подход с участием квалифицированных медицинских специалистов.

Цель исследования — обзор источников литературы по вопросам скрининга и диагностики различных заболеваний в практической деятельности врача с применением ИИ.

МЕТОДОЛОГИЯ ИССЛЕДОВАНИЯ

Авторами был произведен поиск публикаций в базах данных PubMed, Web of Science, Scopus, CyberLeninka, eLibrary и Google Scholar. Поиск осуществлялся по ключевым терминам:

«screening», «diagnostics», «artificial intelligence», «machine learning», «disease», «скрининг», «диагностика», «искусственный интеллект», «заболевание», «машинное обучение», «глубокое обучение». Три автора отдельно друг от друга выполняли отбор подходящих исследований. В обзор включались оригинальные работы, опубликованные на русском и английском языках с 2015 по 2025 годы. В настоящий обзор было включено 31 исследование (рисунок 1). Авторы проанализировали аннотации статей, полный текст, далее извлекали данные для формирования резюме. Во время проведения работы обсуждались разные мнения, в случае несогласия включения исследования в анализ приглашался четвертый коллега, по результатам консилиума принималось общее решение.

Из выборки удалялись публикации, которые по содержащимся в них данным, относились к нерелевантным областям. Чтобы определить принадлежность публикации к предметной области, находились определяющие термины в заглавии, аннотации и ключевых словах. С помощью анализа ключевых слов предшествующей выборки искали термины, не относящиеся к тематике исследования. Публикации, содержащие эти термины, исключались из рассмотрения. За несоответствие

тематике исследования из выборки удалялись публикации или группы публикаций, сформированные в результате, когда две работы ссылаются на общую третью в списках литературы.

В поиск не включались тезисы, опубликованные в материалах научных конференций, и диссертационные исследования, поскольку такая информация крайне редко включает приоритетные аспекты для извлечения данных. Из рассмотрения исключены следующие категории публикаций: эмпирические и методологические изыскания, а также нарративные обзоры и методические руководства, обзоры систематического характера, не содержащие данных о методах моделирования с применением ИИ, либо такие, из которых невозможно выделить результаты работы. Так как число найденных источников оказалось существенным, проводилось автоматическое удаление повторяющихся записей.

Оценка качества статей не проводилась ввиду отсутствия в большинстве случаев классической схемы со сравнением разных групп, которая не соблюдалась в отобранных нами статьях.

Синтез (обобщение) данных. В каждой статье выделялись следующие данные:

– характеристики выборки, если они приводились (возраст, пол, размер выборки);

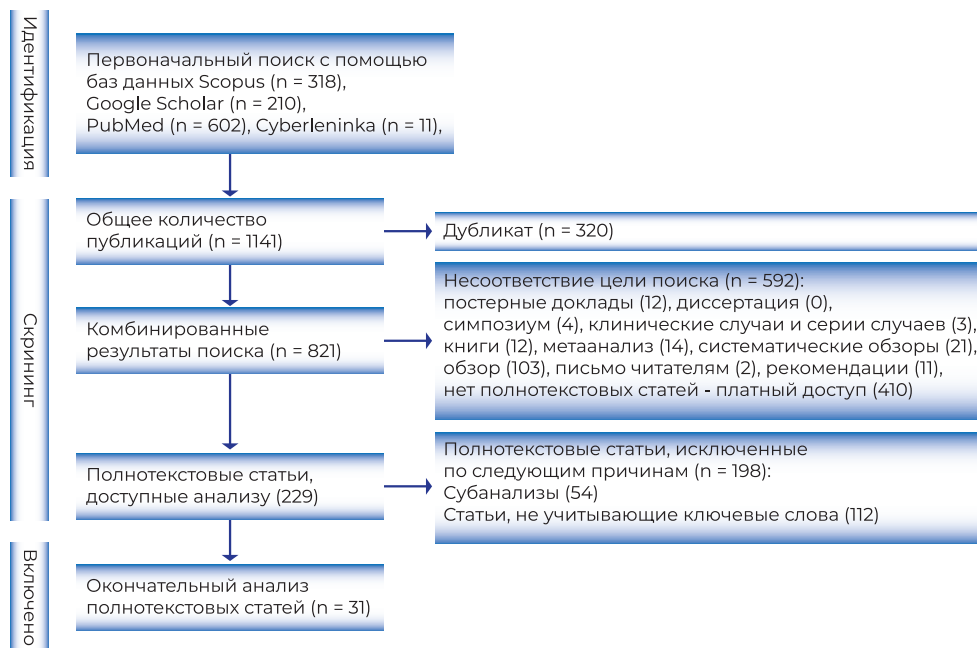


Рисунок 1 – Алгоритм отбора публикаций для написания систематического обзора.

– характеристики прогностической модели ИИ (название способа, вид, характеристика модели, сравнение с контрольной группой).

РЕЗУЛЬТАТЫ

Блок-схема включенных исследований представлена на рисунке 1.

Основные характеристики статей, отвечающих критериям включения, представлены в таблице 1.

Как видно из представленных работ, применение методов ИИ позволяет решить разные задачи в области инфекционных заболеваний (предсказание развития сепсиса [20], оценка тяжести заболевания, определенной с помощью КТ, и временем от начала заболевания до КТ у пациентов при пневмонии, вызванной COVID-19 [33]), хирургических заболеваний (предупреждение о надвигающейся гипотензии в интраоперационном периоде [22]), нейрохирургии (для повышения точности компьютерной диагностики стеноза межпозвоночного отверстия [29]), соматической патологии (выделение фенотипов псориатического артрита [36], клиническая диагностика IgA-нефропатии [40], диагностика и классификация атрофии желудка и кишечной метаплазии [43], скрининг заболеваний органов грудной клетки (ателектаз, фиброз, кальцификация, уплотнения, узловые образования в легких, кардиомегалия, расширение средостения, плевральный выпот, пневмоторакс и пневмоперитонеум) [44], верификация инсульта с применением портативного устройства для отслеживания движения глаз [39]), риск развития сердечной недостаточности у пациентов с сахарным диабетом 2 типа [5]), в гинекологии (предсказание спонтанных аборт [40]), в том числе при использовании методов нетрадиционной медицины [41].

В кардиологической практике моделирование направлено на решение следующих вопросов: феногруппирование пациентов с сердечной недостаточностью и выявление больных с положительным ответом на сердечную ресинхронизирующую терапию [21], кардиоренальные осложнения при сахарном диабете с установленной клинической оценкой нефропатии [23], предсказание подходящей терапии имплантируемого кардиовертера-дефибриллятора при желудочковой тахикардии или фибрилляции

желудочков [25], выявление недиагностированной фибрилляции предсердий (ФП) в первичной медицинской помощи [32], эхокардиографические фенотипы предсказания сердечной недостаточности [35].

Конечно, в области онкологических состояний отдается предпочтение использованию ИИ для: прогнозирования патологических изменений у сложной группы пациентов с ВПЧ-ассоциированной карциномой ротоглотки [24], 5-летней выживаемости пациентов с раком молочной железы [26], риска остеосаркомы в популяционной когорте и оценки факторов, влияющих на возникновение легочных метастазов [29], метастазов на ранних стадиях инвазивного рака молочной железы [30], немелкоклеточного рака легких [25], прогрессирования опухоли при глиобластоме [34], патологической классификации менингиом [37], выявление рака легких на ранней стадии с помощью автоматизированной проточной цитометрии мокроты [39], рака предстательной железы на основе диагностических характеристик моделей позитронно-эмиссионной томографии/магнитно-резонансной томографии (ПЭТ/МРТ) с [68Ga]Ga-PSMA-11 in vivo для прогнозирования низкого и высокого риска поражения, а также биохимического рецидива и общего риска [41], определения скорости роста рака молочной железы (PMЖ) in vivo [42], нахождения очагов поражения при раке легкого на низкодозовых КТ [39].

В педиатрии использование ИИ необходимо для определения прогностического фенотипа детей с детским центральным параличом, которым требуются инъекции нейротоксинов [27], определение постинфекционной детской гидроцефалии [38].

Методы машинного и глубокого обучения включали разнообразные методы, в частности, случайный лес (random forest), в том числе по тесту Делонга, многоядерное обучение и классификация с использованием К-средних, классификация ENE, нейросетевое моделирование, модель XGBoost модель CatBoost, модели логистической регрессии (LR) и метод опорных векторов (SVM) (по тесту Делонга), анализ кривой принятия решения (DCA) и кривой клинического воздействия (CIC), модель BTEX-PredictMed. дерево принятия решений, классификация градиентного бустинга, алгоритм ИИ Lunit INSIGHT CXR, регрессия Кокса.

Таблица 1 – Характеристика исследований

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
1	Морозов С.П. (2020) [1]	От 55 до 80 лет (средний возраст мужчин 64,8±9,4 года, женщин 65,9±8,3 года)	80 мужчин и 20 женщин	100	Алгоритм ИИ S. Trajanovski et al. (2019). Алгоритм на основе двухэтапного метода: 1 этап – детектор для идентификации очагов КТ; 2 этап – нейронная сеть (архитектура ResNet), регуляризованная с помощью случайного отключения нейронов (dropout)	Машинное обучение	Чувствительность – 0,817, специфичность – 0,925, точность – 0,860, площадь под характеристической кривой – 0,930 (95% ДИ 0,880–0,979)	Сопоставление полученных значений с итогами собственного тестирования свидетельствует о хорошей воспроизводимости результатов работы ИИ на независимых данных
2	Бородулина Е.А. (2025) [4]	Не указан	Не указан	2345 исследований	Основой работы интеллектуального блока ИИ-сервиса является сверточная нейронная сеть, обученная для детекции и локализации легочных патологий. Дополнительным элементом является многослойный нейросетевой классификатор, который выполнял функции распознавания классов патологий, детектированных и локализованных на изображениях.	Нейросетевые алгоритмы	Максимизация прогностической ценности отрицательного результата: чувствительность 96%, специфичность 61%, точность 81%, площадь под кривой рабочих характеристик ROC 0,91–0,93	ROC ИИ соответствует аналогичным показателям квалифицированных рентгенологов (0,78–0,91)

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
3	Segar MW et al. (2024) [5]	Средний возраст: 62,7 (6,6) лет	Женщины 3370 (38,5%)	8756	Методы случайного леса для прогнозирования выживаемости (RSF), непараметрический подход на основе дерева принятия решений,	Машинное обучение	Применение RSF, и моделирование взаимосвязи с RSF - С-индекса 0,77 (95% ДИ 0,75–0,80, $p < 0,001$). Калибровка модели, основанной на RSF, оказалась приемлемой (статистика Хосмера-Лемешоу $\chi^2 = 9,63$, $p = 0,29$)	Применение RSF – общий С-индекс 0,74 (95% ДИ 0,71–0,74), по сравнению с методами поэтапного прямого отбора, равными 0,71 (95% ДИ 0,67–0,74) и обратного отбора, равными 0,73 (95% ДИ 0,70–0,76), при использовании моделирования зависимости РН Кокса ($p < 0,01$ и $p = 0,01$, соответственно)
4	Mertens S. et al. (2021) [14]	Не указан	Не указан		Кластерное рандомизированное перекрестное контролируемое исследование с применением программы – нейронная сеть для обнаружения кариеса (dentalXrai Pro, dentalXrai Ltd.)	Сверточная нейронная сеть	Чувствительность 0,81, 95% ДИ 0,74–0,87 ROC 0,89, 95% ДИ 0,87–0,90	Без применения ИИ метрики ниже: ROC 0,85; 95% ДИ 0,83–0,86; $p < 0,05$, чувствительность 0,72; 95% ДИ 0,64–0,79 ($p < 0,05$) без изменения специфичности ($p > 0,05$)
5	Wang D. et al. (2021) [20]	Не указан	Не указан	4449	Случайный лес	Машинное обучение	Площадь AUC составила 0,91, чувствительность – 87%, специфичность – 89%	Не указано
6	Cikes M. et al. (2018) [21]	Не указан	Не указан	1106	Множественное ядерное обучение и кластеризация методом k-средних	Машинное обучение	Не указана	Отношение рисков (ОР) 0,35; 95% доверительный интервал (ДИ) 0,19–0,64; $p = 0,0005$ и ОР 0,36; 95% ДИ 0,19–0,68; $p = 0,001$

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
7	Wijnberge M. et al. (2020) [22]	Средний возраст — 64 года	43% женщин	68	Система раннего оповещения на основе машинного обучения	Машинное обучение	Не указана	Среднее время с момента возникновения гипотензии у одного пациента составило 8,0 минут в группе вмешательства по сравнению с 32,7 минутами в контрольной группе
8	Januzzi JJ, et al. (2025) [23]	Не указан	Не указан	Не указана	Многопараметрическая модель машинного обучения	Машинное обучение	Не указана	Точность модели оценки риска была подтверждена в отдельных когортах исследования CREDENCE и в исследовании Canagliflozin Cardiovascular Assessment Study
9	Kann B.H. et al. (2023) [24]	Не указан	Не указан	178 сканирований	Алгоритм глубокого обучения на основе компьютерной томографии	Глубокое обучение	AUC алгоритма глубокого обучения для классификации ENE составил 0,86 (95% ДИ 0,82–0,90)	Алгоритм показал лучшую производительность по сравнению с рентгенологами для ENE размером более 1 мм и в узлах с диаметром короткой оси 1 см или больше
10	Ginder C. et al. (2023) [25]	Средний возраст — 64 года	26% женщин	2718	Многофакторная логистическая регрессия и нейронные сети	Машинное обучение	Логистическая регрессия: AUC 0,72; нейронные сети: AUC 0,90	Логистическая регрессия (чувствительность 39%, специфичность 91%, AUC 0,72). Нейросетевое моделирование ($p < 0,01$ для сравнения) (чувствительность 54%, специфичность 96%, AUC 0,90)

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
11	Yu W. et al. (2023) [26]	Не указан	Не указан	13 802	LASSO, логистическая регрессия, случайный лес, SVM, XGBoost	Машинное обучение	XGBoost: AUC = 0,8400 в обучающей группе; AUC = 0,8365 в проверочной группе	Не указана
12	Bertoncelli C.M. et al. (2022) [27]	Средний возраст 16,5±1,2	Не указан	165	Модель машинного обучения ВТХ-PredictMed	Машинное обучение	Средняя точность, чувствительность и специфичность составили 75%	Эффективность 75%
13	Su Z. et al. (2023) [28]	Не указан	Не указан	612	Логистическая регрессия, LASSO, многофакторная логистическая регрессия		AUC = 0,701 в обучающей когорте; AUC = 0,786 в проверочной когорте	Не указана
14	Wang H. et al. (2022) [29]	Не указан	Не указан	86	Алгоритм автоматической оценки изображений межпозвоночных отверстий с помощью глубокого обучения	Машинное обучение	Традиционный классификатор 1-NN (точность от 51,8±2,5 до 61,3±0,7, F1 от 0,517 до 0,768) ELM (точность от 51,3±2,1 до 65,4±3,8, F1 от 0,697 до 0,786)	Не указана
15	Yu Y. и др. (2021) [30]	Не указан	Не указан	1088	Радиомика МРТ, машинное обучение, метод опорных векторов	Машинное обучение	AUC радиомики: 0,88; AUC мультиомической сигнатуры: 0,90	Мультиомная сигнатура показала более высокую прогностическую ценность
16	Chen Y. et al. (2022) [31]	Не указан	Не указан	104	Система чтения изображений на основе ИИ и глубокого обучения	Глубокое обучение	Чувствительность рентгенологов: 72,94% Чувствительность системы ИИ: 94,12%	Система ИИ показала более высокую чувствительность (p<0,05)
	Hill N.R. et al. (2022) [32]	≥30 лет	Не указан	Не указан	Алгоритм прогнозирования риска ФП на основе машинного обучения	Машинное обучение	Стратегия скрининга экономически эффективна при определённых условиях	Стратегия скрининга экономически эффективна для выявления ФП
17	Ohno Y. et al. [33]	Не указан	Не указан	32	Алгоритм ИИ для диагностики пневмонии, вызванной COVID-19, количественный анализ текстуры КТ	Машинное обучение	Оценка тяжести заболевания по КТ: 62,5%. Точность комбинированного количественного метода: 87,5%	Комбинированный количественный метод показал более высокую точность

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
18	George E. et al. (2022) [34]	Средний возраст 55,2 года	69% мужчины	113	Машинное обучение на основе радиомики для прогнозирования результатов иммунотерапии при глиобластоме	Машинное обучение	Характеристики МРТ до лечения имели низкую прогностическую ценность. Прогностическая ценность первых результатов МРТ во время лечения: индекс согласованности = 0,692–0,750	Модель МО на основе радиомики позволяет прогнозировать выживаемость пациентов
19	Kobayashi M. et al. (2022) [35]	Средний возраст: 60±5 лет (STANISLAS); 67±6 лет (Malmö)	Мужчины: 48% (STANISLAS); 70% (Malmö)	827 (STANISLAS); 1394 (Malmö)	Эхокардиографические фенотипы, выявленные с помощью машинного обучения	Машинное обучение	Фенотипы ДИ и ДИ/СР связаны с более высоким риском развития цереброваскулярной болезни и гипертрофии левого желудочка	Классификация на основе эхокардиографических данных выявила профили с различным долгосрочным риском развития сердечной недостаточности
20	Richette P. et al. (2023) [36]	Не указан	Мужчины и женщины	661	Неотрицательная матричная факторизация для выявления кластеров фенотипов ПсА	Машинное обучение без учителя	Ответ на лечение гуселькумабом различался в зависимости от кластера	Выявлено восемь кластеров фенотипов ПсА со значительными различиями в демографических характеристиках, клинических проявлениях и реакции на лечение
21	Wang X. et al. (2022) [37]	Не указан	Не указан	120	Модель на основе неконтролируемой кластеризации Multihabitat для прогнозирования патологической классификации менингиом	Машинное обучение без учителя	Площадь под кривой: 0,838 в обучающей группе; 0,73 в тестовой группе Обучающая группа: 67,65%; тестовая группа: 69,05%	Модель продемонстрировала большой потенциал для практического применения

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
22	Harper J.R. et al. (2021) [38]	Не указан	Не указан	Не указан	Оценка эффективности визуализации головного мозга с низким разрешением: лечение гидроцефалии у младенцев	Глубокое обучение	Не указана	Изображения низкого качества могут быть полезны для планирования лечения гидроцефалии, но могут содержать вводящую в заблуждение информацию при улучшении с помощью глубокого обучения
23	Lemieux M.E. et al. (2023) [39]	Не указан	Не указан	182	CyPath Lung: анализ мокроты с помощью автоматизированной проточной цитометрии и машинного обучения	Машинное обучение	AUC: 0,89 (95% ДИ 0,83–0,89) в первой группе; AUC: 0,85 (95% ДИ 0,71–0,98) во второй группе	Тест показал высокую чувствительность и специфичность для классификации образцов как раковых или нераковых, в том числе у участников с разными стадиями заболевания и узелками диаметром менее 20 мм
24	Qin X. et al. (2023) [40]	Не указан	Не указан	120	Разработка новой комбинированной номограммы, объединяющей радиомику на основе глубокого обучения, для клинической диагностики IgA-нефропатии	Глубокое обучение	ROC-кривая модели радиомики: 0,816; ROC-кривая модели глубокого обучения: 0,844; ROC комбинированной номограммы: 0,884	Комбинированная номограмма в сочетании с независимыми клиническими факторами риска показала сильную дискриминацию и клиническую применимость
25	Papp L. et al. (2025) [41]	Не указан	Мужчины	52	Машинное обучение с учителем для определения характера поражения при первичном раке предстательной железы с помощью ПЭТ/МРТ [68Ga] Ga-PSMA-11	Машинное обучение с учителем	Точность стандартного анализа на основе ПСА, индекса Глисона и стадии TNM: 69% и 70% для прогнозирования BCR и OPR соответственно Точность моделей MBCR и MOPR: 89% и 91% соответственно	Модели на основе радиомики ПЭТ/МРТ и машинного обучения показали более высокую точность по сравнению со стандартным анализом

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
26	Bhattarai S. et al. (2019) [42]	Не указан	Женщины	Не указан	Прогнозирование скорости роста рака молочной железы in vivo на основе машинного обучения	Машинное обучение	Surr-INVIGOR стратифицировала опухоли и совпала с SM-INVIGOR в когорте исследования; в когорте валидации выявила значительные различия в выживаемости между пациентами с быстрорастущими и медленно растущими опухолями	Surr-INVIGOR прогнозирует скорость роста рака молочной железы in vivo и предлагает несколько полезных вариантов применения
27	Fang S. et al. (2024) [43]	Не указан	Не указан	545	Диагностика и оценка степени атрофии желудка и кишечной метаплазии с помощью полуконтролируемого глубокого обучения на патологических изображениях	Чувствительность и специфичность патологоанатомов не указаны	AUC для диагностики атрофии: 0,877; чувствительность: 80%; специфичность: 85%	GasMIL превзошёл результаты всех десяти патологоанатомов в диагностике атрофии и показал улучшение показателей AUC, чувствительности и специфичности при диагностике интрамуральной опухоли
28	van Beek EJR. (2023) [44]	Диапазон возраста: 13–102 года	Мужчины: 49% Женщины: 51%	1960	Lunit INSIGHT CXR (версия 3.1.2.0)	Полуконтролируемое глубокое обучение	AUC: 0,881–0,999 (ED)	AUROC алгоритма сопоставима с экспертами, за исключением выпота ($p < 0,001$)
29	Lu Q. et al. (2023) [45]	Средний возраст: 62,1 года	Мужчины: 23; Женщины: 17	40	Анализ движений глаз под 5-цветными стимулами + RF	Машинное обучение (SVM)	AUC: 88,45 (красный стимул); F1: 85,47	RF и CatBoost показали наилучшие результаты
30	Huang Z. et al. (2022) [46]	Не указан	Не указан	393	Классификация свойств «холод-жар» по молекулярным данным	Машинное обучение (RF, CatBoost и др.)	AUC: 0,82	Модель выявляет структурные различия молекул
31	Liu Y. et al. (2022) [47]	22–45	Женщины	663	GBDT на основе конституции ТКМ и клинических данных	RF + GNB	AUC для диагностики атрофии: 0,877; чувствительность: 80%; специфичность: 85%	GBDT показал наилучший результат среди 8 моделей

Исходя из данных таблицы 1, можно сделать вывод, что метрики разработанных моделей указывают на удовлетворительное или хорошее качество, что определяется чувствительностью, специфичностью, диагностической точностью, площадью под кривой AUC. Созданные алгоритмы продемонстрировали улучшенную производительность по сравнению с результатами работы врача, который традиционными методами, в том числе визуально, определял вероятность наличия патологического состояния. Важным аспектом является то, что разработанные модели проходят проверку на тестовой выборке и валидационной выборке, что позволяет судить об эффективности применения ИИ для задач практического здравоохранения.

Таким образом, такие методы ИИ, как машинное обучение, нейронные сети, применялись наиболее часто; случайный лес и нейронные сети продемонстрировали наибольшую точность; основные параметры в проанализированных публикациях — чувствительность, специфичность, ROC-анализ, AUC. Исследователями отмечены следующие недостатки и ограничения: если система обучена на недостаточно репрезентативных данных, она может демонстрировать предвзятость к определённым группам пациентов; многие современные алгоритмы, особенно основанные на глубоком обучении, не могут объяснить логику своих решений. Наиболее перспективные направления для будущих исследований включают анализ данных с носимых устройств, когда нейросеть сможет корректировать дозу препаратов и предупреждать врача о риске обострения, анализ генетических мутаций опухоли и предложение оптимальной комбинации препаратов, внедрение круглосуточных консультантов, отслеживающих режим приёма лекарств и динамику состояния.

ОБСУЖДЕНИЕ

Существует два основных метода выявления заболеваний, в том числе онкологических, ССЗ, инфекционных (туберкулез) на ранней стадии: скрининг и диагностика. Скрининг — это диспансеризация большого количества потенциально здоровых пациентов с целью выявления больных людей, требующих последующего индивидуального обследования, диагностика — персонализированное обследование пациентов с определенным набором жалоб. Указанные методы обладают

своей спецификой. Скрининг позволяет обнаружить бессимптомное течение заболевания в ходе проведения массового обследования большой выборки, диагностика способствует детальному обследованию пациентов с жалобами для исключения или подтверждения наличия патологии.

Несмотря на кажущееся преимущество, для метода скрининга характерен ряд сложностей, препятствующих повышению ранней диагностики заболевания. Из-за большого объема исследований затягивается процесс постановки диагноза. С целью уменьшения влияния данного фактора разработаны технологии ИИ, которые активно развиваются и используются в разных областях общественной жизни. Многие авторы подчеркивают существенную экономию времени, потраченного на подготовку заключений. Оптимальная точка отсечения для скрининговых исследований должна определяться исходя из показателя максимальной предсказательной способности отрицательных результатов [1, 4]. Технология «компьютерное зрение» (Computer Vision) для автоматической интерпретации исследований МРТ, КТ, флюорографии и маммографии является современным ИИ-решением, применяемым в лучевой диагностике.

Особенности использования ИИ в выявлении заболеваний продиктованы основными принципами работы. Здесь можно подчеркнуть роль ИИ как помощника врача, а не его замены. Основные положения включают двойную проверку результатов, сопоставление выводов ИИ с мнением специалиста, защиту медицинских данных, необходимость дополнительного обучения систем. Несмотря на очевидные преимущества использования ИИ для задач практикующего врача, существует ряд ограничений. Это необходимость в качественных обучающих базах данных, правовые и этические вопросы, включая защиту персональных данных, потребность в верификации и сертификации ИИ-решений [48–50]. Применение ИИ требует формирование набора данных. Размерность и полнота заполнения набора данных будет определять результат работы.

В ближайшие годы ожидается более широкое внедрение ИИ в медицинскую деятельность, что предоставит возможность значительно улучшить уровень профилактики и ранней диагностики различных заболеваний, в первую очередь, жизнеугрожающих и смертельных состояний.

ЗАКЛЮЧЕНИЕ

Наибольший прогресс в применении ИИ отмечен в расшифровке рентгеновских снимков, МРТ и КТ. ИИ зарекомендовал себя ещё в период пандемии COVID-19 при анализе снимков оптической когерентной томографии. Перспективы включают персонализированное лечение, что обеспечивается комплексной оценкой генетических данных, анамнеза, биомаркеров, результатов анализов с помощью ИИ; системы прогнозирования осложнений хронических заболеваний на основе постоянного мониторинга, технологию анализа микробиома для

диагностики широкого спектра патологий. При этом выделяются определенные ограничивающие аспекты: необходимы структурированные и размеченные данные для проведения качественных исследований в области медицинской диагностики; скептицизм медицинского сообщества и пациентов (как медицинский персонал, так и пациенты с осторожностью относятся к прогнозам и прогнозам ИИ); правовые стандарты (в российском законодательстве до сих пор не существует определённых стандартов, которые регламентируют работу медицинских ИИ-сервисов).

ЛИТЕРАТУРА/REFERENCES

1. Морозов С.П., Владимирский А.В., Гомболевский В.А., Кляшторный В.Г., Федуллова И.А., Власенков Л.А. Искусственный интеллект в скрининге рака легкого: оценка диагностической точности алгоритма для анализа низкодозовых компьютерных томографий // Туберкулёз и болезни лёгких. — 2020. — Т.98. — №8. — С.24-31. [Morozov SP, Vladimirovskiy AV, Gombolevskiy VA, Klyashtorniy VG, Fedulova IA, Vlasenkov LA. Artificial intelligence in lung cancer screening: assessment of the diagnostic accuracy of the algorithm analyzing low-dose computed tomography. Tuberculosis and Lung Diseases. 2020; 98(8): 24-31. (In Russ.)] doi: 10.21292/2075-1230-2020-98-8-24-31.
2. Pei Q, Luo Y, Chen Y, Li J, Xie D, Ye T. Artificial intelligence in clinical applications for lung cancer: diagnosis, treatment and prognosis. Clin Chem Lab Med. 2022; 60(12): 1974-1983. doi: 10.1515/cclm-2022-0291.
3. Качаева Г.И., Мустафаев А.Г. Использование нейросетевых методов для автоматического анализа электрокардиограмм при диагностике заболеваний сердечно-сосудистой системы. Вестник Дагестанского государственного технического университета // Технические науки. — 2018. — №45(2). — С.114-124. [Kachaeva GI, Mustafayev AG. The use of neural networks for the automatic analysis of electrocardiograms in diagnosis of cardiovascular diseases. Herald of Dagestan State Technical University. Technical Sciences. 2018; 45(2): 114-124. (In Russ.)] doi: 10.21822/2073-6185-2018-45-2-114-124.
4. Бородулина Е.А., Гогоберидзе Ю.Т., Просвиркин И.А. и др. Оценка эффективности использования технологий искусственного интеллекта для скрининга заболеваний легких в муниципальной больнице // Сибирский журнал клинической и экспериментальной медицины. — 2025. — №40(1). — С.209-217. [Borodulina EA, Gogoberidze YT, Prosvirkin IA, et al. Effectiveness of artificial intelligence for lung disease screening in a municipal hospital. Siberian Journal of Clinical and Experimental Medicine. 2025; 40(1): 209-217. (In Russ.)] doi: 10.29001/2073-8552-2025-40-1-209-217.
5. Segar MW, Vaduganathan M, Patel KV, et al. Machine Learning to Predict the Risk of Incident Heart Failure Hospitalization Among Patients With Diabetes: The WATCH-DM Risk Score Diabetes Care 2019; 42: 2298-2306. doi: 10.2337/dc19-0587.
6. Сервис поддержки принятия врачебных решений для диагностики новообразований кожи ПроРодинки по ТУ 58.29.32-001-43490523-2022. Регистрационное удостоверение медицинского изделия. № РЗН 2023/21776, Приказ от 27.12.23 №9743. [Servis podderzhki prinyatiya vrachebnyh reshenij dlya diagnostiki novoobrazovanij kozhi ProRodinki po TU 58.29.32-001-43490523-2022. Registracionnoe udostoverenie medicinskogo izdeliya. № RZN 2023/21776, Prikaz ot 27.12.23 №9743. (In Russ.)]
7. Freeman K, Dinnes J, Chuchu N, et al. Algorithm based smartphone apps to assess risk of skin cancer in adults: systematic review of diagnostic accuracy studies. BMJ. 2020; 368: m127. doi: 10.1136/bmj.m127.
8. Владимирова Ю.В., Тюриков М.И., Лоскутов И.А., Каталевская Е.А. Программа скрининга диабетической ретинопатии на основе алгоритмов искусственного интеллекта // Эффективная фармакотерапия. — 2024. — №20(15): 60-63. [Vladimirova YUV, Tyurikov MI, Loskutov IA, Kataljevskaya EA. Programma skrininga diabeticheskoj retinopatii na osnove algoritmov iskusstvennogo intellekta. Effektivnaya farmakoterapiya. 2024; 20(15): 60-63. (In Russ.)] doi: 10.33978/2307-3586-2024-20-15-60-63.
9. Ezra Receives 510(k) FDA Clearance for AI that enhances MRI, enabling fast, low-cost scans.

10. Perelomova PA. Automatic recognition of pathologies on X-ray, CT and MRI images. *International scientific journal Bulletin of Science*. 2025; 1(3)(84): 520-525.
11. Varma N, Cygankiewicz I, Turakhia M. 2021 ISHNE/HRS/EHRA/APHRs Collaborative Statement on mHealth in Arrhythmia Management: Digital Medical Tools for Heart Rhythm Professionals. *Russian Journal of Cardiology*. 2021; 26(15): 4420.
12. Ilhan B, Lin K, Guneri P, Wilder-Smith P. Improving Oral Cancer Outcomes with Imaging and Artificial Intelligence. *J Dent Res*. 2020; 99(3): 241-248. doi: 10.1177/0022034520902128.
13. Pitchika V, Büttner M, Schwendicke F. Artificial intelligence and personalized diagnostics in periodontology: A narrative review. *Periodontol 2000*. 2024; 95(1): 220-231. doi: 10.1111/prd.12586.
14. Mertens S, Krois J, Cantu AG, Arsiwala LT, Schwendicke F. Artificial intelligence for caries detection: Randomized trial. *J Dent*. 2021; 115: 103849. doi: 10.1016/j.jdent.2021.103849.
15. Shmatko A, Ghaffari Laleh N, Gerstung M, Kather JN. Artificial intelligence in histopathology: enhancing cancer research and clinical oncology. *Nat Cancer*. 2022; 3(9): 1026-1038. doi: 10.1038/s43018-022-00436-4.
16. Koski E, Murphy J. AI in Healthcare. *Stud Health Technol Inform*. 2021; 284: 295-299. doi: 10.3233/SHTI210726. PMID: 34920529.
17. Li JO, Liu H, Ting DSJ, et al. Digital technology, tele-medicine and artificial intelligence in ophthalmology: A global perspective. *Prog Retin Eye Res*. 2021; 82: 100900. doi: 10.1016/j.preteyeres.2020.100900.
18. Sung J. Artificial intelligence in medicine: Ethical, social and legal perspectives. *Ann Acad Med Singap*. 2023; 52(12): 695-699. doi: 10.47102/annals-acadmedsg.2023103.
19. Lorkowski J, Kolaszyńska O, Pokorski M. Artificial Intelligence and Precision Medicine: A Perspective. *Adv Exp Med Biol*. 2022; 1375: 1-11. doi: 10.1007/5584_2021_652.
20. Wang D, Li J, Sun Y, et al. A Machine Learning Model for Accurate Prediction of Sepsis in ICU Patients. *Front Public Health*. 2021; 9: 754348. doi: 10.3389/fpubh.2021.754348.
21. Cikes M, Sanchez-Martinez S, Claggett B, et al. Machine learning-based phenotyping in heart failure to identify responders to cardiac resynchronization therapy. *Eur J Heart Fail*. 2019; 21(1): 74-85. doi: 10.1002/ejhf.1333.
22. Wijnberge M, Geerts BF, Hol L, et al. Effect of a Machine Learning-Derived Early Warning System for Intraoperative Hypotension vs Standard Care on Depth and Duration of Intraoperative Hypotension During Elective Noncardiac Surgery: The HYPE Randomized Clinical Trial. *JAMA*. 2020; 323(11): 1052-1060. doi: 10.1001/jama.2020.0592.
23. Januzzi JL, Sattar N, Vaduganathan M, Magaret CA, et al. A validated multivariable machine learning model to predict cardio-kidney risk in diabetic kidney disease. *Cardiovasc Diabetol*. 2025; 24(1): 213. doi: 10.1186/s12933-025-02779-5.
24. Kann BH, Likitlersuang J, Bontempi D, et al. Screening for extranodal extension in HPV-associated oropharyngeal carcinoma: evaluation of a CT-based deep learning algorithm in patient data from a multicentre, randomised de-escalation trial. *Lancet Digit Health*. 2023; 5(6): e360-e369. doi: 10.1016/S2589-7500(23)00046-8.
25. Ginder C, Li J, Halperin JL, et al. Predicting Malignant Ventricular Arrhythmias Using Real-Time Remote Monitoring. *J Am Coll Cardiol*. 2023; 81(10): 949-961. doi: 10.1016/j.jacc.2022.12.024.
26. Yu W, Lu Y, Shou H, et al. A 5-year survival status prognosis of nonmetastatic cervical cancer patients through machine learning algorithms. *Cancer Med*. 2023; 12(6): 6867-6876. doi: 10.1002/cam4.5477.
27. Bertocelli CM, Latalski M, Bertocelli D, et al. Prediction Model for Identifying Computational Phenotypes of Children with Cerebral Palsy Needing Neurotoxin Treatments. *Toxins (Basel)*. 2022; 15(1): 20. doi: 10.3390/toxins15010020.
28. Su Z, Huang F, Yin C, Yu Y, Yu C. Clinical model of pulmonary metastasis in patients with osteosarcoma: A new multiple machine learning-based risk prediction. *J Orthop Surg (Hong Kong)*. 2023; 31(2): 10225536231177102. doi: 10.1177/10225536231177102.
29. Wang H, Liu Y, Li Y. Study on Automatic Multi-Classification of Spine Based on Deep Learning and Postoperative Infection Screening. *J Healthc Eng*. 2022; 2022: 2779686. doi: 10.1155/2022/2779686.
30. Yu Y, He Z, Ouyang J, et al. Magnetic resonance imaging radiomics predicts preoperative axillary lymph node metastasis to support surgical decisions and is associated with tumor microenvironment in invasive breast cancer: A machine learning, multicenter study. *EBioMedicine*. 2021; 69: 103460. doi: 10.1016/j.ebiom.2021.103460.
31. Chen Y, Tian X, Fan K, Zheng Y, Tian N, Fan K. The Value of Artificial Intelligence Film Reading System Based on Deep Learning in the Diagnosis of Non-Small-Cell Lung Cancer and the Significance of Efficacy Monitoring: A Retrospective, Clinical, Nonrandomized, Controlled Study. *Comput Math Methods Med*.

- 2022; 2022: 2864170. doi: 10.1155/2022/2864170. Retraction in: *Comput Math Methods Med.* 2023 Oct 4; 2023: 9823173. doi: 10.1155/2023/9823173.
32. Hill NR, Groves L, Dickerson C, et al. Identification of undiagnosed atrial fibrillation using a machine learning risk prediction algorithm and diagnostic testing (PULsE-AI) in primary care: cost-effectiveness of a screening strategy evaluated in a randomized controlled trial in England. *J Med Econ.* 2022; 25(1): 974-983. doi: 10.1080/13696998.2022.2102355.
 33. Ohno Y, Aoyagi K, Arakita K, Doi Y, et al. Newly developed artificial intelligence algorithm for COVID-19 pneumonia: utility of quantitative CT texture analysis for prediction of favipiravir treatment effect. *Jpn J Radiol.* 2022; 40(8): 800-813. doi: 10.1007/s11604-022-01270-5.
 34. George E, Flagg E, Chang K, et al. Radiomics-Based Machine Learning for Outcome Prediction in a Multicenter Phase II Study of Programmed Death-Ligand 1 Inhibition Immunotherapy for Glioblastoma. *AJNR Am J Neuroradiol.* 2022; 43(5): 675-681. doi: 10.3174/ajnr.A7488.
 35. Kobayashi M, Huttin O, Magnusson M, et al. STANISLAS Study Investigators. Machine Learning-Derived Echocardiographic Phenotypes Predict Heart Failure Incidence in Asymptomatic Individuals. *JACC Cardiovasc Imaging.* 2022; 15(2): 193-208. doi: 10.1016/j.jcmg.2021.07.004.
 36. Richette P, Vis M, Ohrndorf S, et al. Identification of PsA phenotypes with machine learning analytics using data from two phase III clinical trials of guselkumab in a bio-naïve population of patients with PsA. *RMD Open.* 2023; 9(1): e002934. doi: 10.1136/rmdopen-2022-002934.
 37. Wang X, Li J, Sun J, et al. A Machine Learning Model Based on Unsupervised Clustering Multihabitat to Predict the Pathological Grading of Meningiomas. *Biomed Res Int.* 2022; 2022: 8955227. doi: 10.1155/2022/8955227.
 38. Harper JR, Cherukuri V, O'Reilly T, Yu M, et al. Assessing the utility of low resolution brain imaging: treatment of infant hydrocephalus. *Neuroimage Clin.* 2021; 32: 102896. doi: 10.1016/j.nicl.2021.102896.
 39. Lemieux ME, Reveles XT, Rebeles J, et al. Detection of early-stage lung cancer in sputum using automated flow cytometry and machine learning. *Respir Res.* 2023; 24(1): 23. doi: 10.1186/s12931-023-02327-3.
 40. Qin X, Xia L, Ma Q, Cheng D, Zhang C. Development of a novel combined nomogram model integrating deep learning radiomics to diagnose IgA nephropathy clinically. *Ren Fail.* 2023; 45(2): 2271104. doi: 10.1080/0886022X.2023.2271104.
 41. Papp L, Spielvogel CP, Grubmüller B, et al. Supervised machine learning enables non-invasive lesion characterization in primary prostate cancer with [68Ga] Ga-PSMA-11 PET/MRI. *Eur J Nucl Med Mol Imaging.* 2021; 48(6): 1795-1805. doi: 10.1007/s00259-020-05140-y.
 42. Bhattarai S, Klimov S, Aleskandarany MA, et al. Machine learning-based prediction of breast cancer growth rate in vivo. *Br J Cancer.* 2019; 121(6): 497-504. doi: 10.1038/s41416-019-0539-x.
 43. Fang S, Liu Z, Qiu Q, et al. Diagnosing and grading gastric atrophy and intestinal metaplasia using semi-supervised deep learning on pathological images: development and validation study. *Gastric Cancer.* 2024; 27(2): 343-354. doi: 10.1007/s10120-023-01451-9.
 44. van Beek EJR, Ahn JS, Kim MJ, Murchison JT. Validation study of machine-learning chest radiograph software in primary and emergency medicine. *Clin Radiol.* 2023; 78(1): 1-7. doi: 10.1016/j.crad.2022.08.129.
 45. Lu Q. et al. Machine learning models for stroke detection by observing the eye-movement features under five-color visual stimuli in traditional Chinese medicine. *Journal of Traditional Chinese Medical Sciences.* 2023; 10(3): 321-330. doi: 10.1016/j.jtcm.2023.06.003.
 46. Zhongquan H, Yuqing L, Hongyan C, Geng L, Zhiwei L. Definition of the molecular bases of cold and hot properties of traditional Chinese medicine through machine learning, *Pharmacological Research - Modern Chinese Medicine.* 2022; 4: 100124. doi: 10.1016/j.prmcm.2022.100124.
 47. Yan L, Yangyang G, Liuqing Y, et al. Traditional Chinese Medicine Constitution and Clinical Data Association with Machine Learning for Prediction of Spontaneous Abortion, *Clinical Complementary Medicine and Pharmacology.* 2022; 2(2): 100016. doi: 10.1016/j.ccmp.2021.100016.
 48. Kolla L, Parikh RB. Uses and limitations of artificial intelligence for oncology. *Cancer.* 2024; 130(12): 2101-2107. doi: 10.1002/cncr.35307.
 49. Abdullah YI, Schuman JS, Shabsigh R, Caplan A, Al-Aswad LA. Ethics of Artificial Intelligence in Medicine and Ophthalmology. *Asia Pac J Ophthalmol (Phila).* 2021; 10(3): 289-298. doi: 10.1097/APO.0000000000000397.
 50. Pantanowitz L, Hanna M, Pantanowitz J, et al. Regulatory Aspects of Artificial Intelligence and Machine Learning. *Mod Pathol.* 2024; 37(12): 100609. doi: 10.1016/j.modpat.2024.100609.