

¹ Российский университет медицины

² Национальный медицинский исследовательский центр акушерства, гинекологии и перинатологии им. акад. В.И. Кулакова

³ Российская детская клиническая больница – филиал Российского национального исследовательского медицинского университета им. Н.И. Пирогова

⁴ Российский национальный исследовательский медицинский университет им. Н.И. Пирогова

⁵ Первый Московский государственный медицинский университет им. И.М. Сеченова

Применение искусственного интеллекта в диагностике и лечении гинекологических заболеваний

Л.В. Адамян, д.м.н., проф., академик РАН^{1,2}, Е.В. Сибирская, д.м.н., проф.^{1,3,4}, Л.Г. Пивазян², С.Г. Исаева⁵, С.К. Мурватова⁵, Е.Д. Нахапетян⁴

Адрес для переписки: Елена Викторовна Сибирская, elsibirskaya@yandex.ru

Для цитирования: Адамян Л.В., Сибирская Е.В., Пивазян Л.Г. и др. Применение искусственного интеллекта в диагностике и лечении гинекологических заболеваний. Эффективная фармакотерапия. 2024; 20 (19): 88–95.

DOI 10.33978/2307-3586-2024-20-19-88-95

Искусственный интеллект (ИИ) активно внедряется в современное здравоохранение в качестве синергиста и помощника практикующих врачей. ИИ используется на всех этапах диагностического поиска большинства гинекологических заболеваний, при разработке наиболее эффективного плана лечения и оценке предикторов исхода терапии. Цель обзора – обобщить данные о применении ИИ в гинекологической практике. Представлена общая характеристика видов ИИ. Проанализирована эффективность применения разных методов машинного обучения в диагностике и лечении заболеваний молочной железы, шейки матки и яичников.

Ключевые слова: искусственный интеллект, диагностика, терапия, гинекология

Введение

Искусственный интеллект (ИИ) открывает широкие возможности для улучшения качества оказываемой медицинской помощи во многих странах мира. Методы машинного обучения активно применяются для разработки алгоритмов, направленных на автоматизацию процессов диагностики и подбора лечения исходя из особенностей пациента, что значительно повышает точность и скорость диагностического поиска и эффективность лечения. ИИ позволяет анализировать большие объемы данных, в частности молекулы-предикторы прогрессирования заболеваний, генетические карты и сигнальные пути патологических процессов, которые могут быть полезны для прогнозирования эффективности назначаемого лечения. Однако ИИ не следует рассматривать как единственный способ считывания и анализа полученных данных, ведь прорыв в сфере здравоохранения возможен благодаря синергизму ИИ и врача.

Типы искусственного интеллекта

В медицине выделяют и применяют два основных типа ИИ:

- 1) символический, представляющий собой систему, способную анализировать полученные медицинские данные и на их основании устанавливать связи между симптомами, заболеваниями и вероятными диагнозами;
- 2) несимволический, к которому относится машинное обучение [1].

Машинное обучение – наиболее распространенный и применяемый на сегодняшний день тип ИИ. Создание определенной программы и настройка необходимых параметров позволяют сравнить входные (загружаемые) и выходные (проанализированные программой) изображения. Первоначально данная методика была применена в лучевой диагностике, где ИИ использовался для анализа рентгенологических изображений, а также снимков, полученных при вы-

полнении компьютерной (КТ) и магнитно-резонансной томографии (МРТ), на основании предварительного внесения обучающей базы [2].

Машинное обучение может быть реализовано посредством методов опорных векторов [3], нейронных сетей [4], random forest [5–11] и др. Методы опорных векторов и random forest подходят для работы с комбинациями числовых характеристик, типичных для клинических факторов, таких как возраст, индекс массы тела или вариации числа геномных копий. Обучение с помощью искусственных нейронных сетей (ANN), или глубокого обучения, в настоящее время стало доминирующим инструментом в машинном обучении. Оно включает в себя множество слоев, соединенных «нейронами». Эти слои несут информацию об объектах, описывают иерархию. Иными словами, ANN имитируют интеллект мозга с помощью различных математических уравнений, программного обеспечения или электронных схем. Важным компонентом ANN является метод нормализации, который поддерживает входные и выходные данные в заданных диапазонах, необходимые для считывания результата проведенного анализа.

Особого внимания заслуживает подтип глубоких нейронных сетей – сверточные нейронные сети (CNN), которые применяются для анализа изображений. Для реализации данных изображений, как правило, используются графические процессоры (GPU). CNN позволяют проводить обучение непосредственно на необработанных изображениях и способны извлекать расширенные представления из входных изображений. Однако, несмотря на преимущества, CNN имеет недостатки. Данная модель распознает только те изображения, с параметрами которых ознакомлена. То есть новые изображения, с которыми модель ранее не сталкивалась, плохо поддаются анализу. Именно поэтому необходимо расширять спектр обучения, тем самым создавая общий, а не специализированный алгоритм [12].

Еще одна разновидность машинного обучения – глубокое обучение, позволяющее разрабатывать множество схем автоматизированного обнаружения и диагностики. Оно генерирует новые алгоритмы обработки медицинских изображений. Модели, основанные на глубоком обучении, эффективны благодаря точности в интерпретации результатов. Кроме того, они позволяют более точно установить стадию процесса, что в свою очередь помогает врачу с выбором тактики лечения и значительно снижает риск медицинских ошибок [13].

X. Chen и соавт. описали разные виды глубокого обучения [14]. В зависимости от меток в обучающем наборе глубокое обучение подразделяют на контролируемое, неконтролируемое и полуконтролируемое [15]. Контролируемое помечает все обучающие изображения, а модель оптимизируется с использованием пар «изображение – метка». Для неконтролируемого обучения модель анализирует и изучает лежащие в основе шаблоны или скрытые структуры данных без меток. Полуконтролируемым называется обучение, когда от-

мечена только небольшая часть обучающих данных. Модель изучает взаимосвязь «ввод – вывод» на основании помеченных данных и усиливается за счет изучения семантических и мелкозернистых функций с помощью немаркированных данных [16].

Сегодня глубокое обучение широко применяется в ультразвуковом исследовании яичников. Y. Gao и соавт. в ретроспективном исследовании описали разработанную модель глубокой сверточной нейронной сети (DCNN), которая позволяет автоматизировать оценку ультразвуковых изображений, что способствует более точной диагностике рака яичников [17]. Авторы собрали ультразвуковые изображения органов малого таза из десяти больниц Китая за период с сентября 2003 г. по май 2019 г. Исследователи проанализировали данные пациентов в возрасте ≥ 18 лет с поражениями придатков при ультразвуковом исследовании (УЗИ). В ходе исследования сравнивали диагностическую ценность DCNN и мануального анализа специалистов УЗ-диагностики. Анализ показал, что более точная диагностика рака яичников проведена с помощью DCNN. Средняя точность оценок с помощью ИИ для врачей УЗ-диагностики составила 0,876 и увеличилась при использовании модели глубокой сверточной нейронной сети (DCNN; $p < 0,05$). Таким образом, авторы работы четко показали преимущество УЗИ совместно с моделью DCNN перед мануальной диагностикой рака яичников [18]. Еще одной ветвью машинного обучения является модель random forest (BiMM). Данный метод представляет собой алгоритм машинного обучения, который может применяться для разработки моделей прогнозирования кластеризованных продольных бинарных исходов. Нередко он находит применение в диагностике рака молочной железы. J.L. Spreiser и соавт. использовали указанную модель машинного обучения для создания визуального веб-сервера для прогнозирования иммунного подтипа пациентов с тройным негативным раком молочной железы (TNBC) [19]. Метод random forest послужил основой для создания веб-сервиса, позволяющего строить модель прогнозирования иммунного подтипа рака молочной железы и эффективности ИСВ.

Применение искусственного интеллекта в диагностике рака яичников

В данном случае применение ИИ основано на выявлении и дифференциальной диагностике доброкачественных и злокачественных новообразований яичников исходя из анализа результатов инструментальных исследований (МРТ, КТ, УЗИ) с помощью радиомикки. Этот метод позволяет анализировать количественные показатели радиологических изображений посредством поиска их отличительных особенностей и формирования из них фенотипов патологических образований, что значительно повышает чувствительность расшифровки за счет выявления недоступных человеческому глазу элементов анализируемого изображения. Интеграция автоматизированной сегментации опухолей на основе машинного обучения

необходима как минимум для диагностики рака яичников, поскольку применение более стандартизированных и специализированных подходов к интерпретации изображений способствует формированию окончательного диагноза, основанного на глубоком и послойном анализе предоставленных изображений, исключающем потенциальные ошибки, которые могли возникнуть из-за человеческого фактора.

Так, E. Amidi и соавт. использовали метод опорных векторов (алгоритм контролируемого обучения) и обобщенные линейные модели при анализе изображений, полученных с помощью фотоакустического и ультразвукового исследования, для дифференциальной диагностики доброкачественных и злокачественных образований яичников [20]. Авторы выяснили, что спектральные характеристики, полученные с помощью фотоакустической визуализации, могут быть использованы для классификации рака яичников. При этом именно метод опорных векторов считается наиболее прогрессивным типом машинного обучения в процессе дифференциальной диагностики новообразований яичников, поскольку связан с неструктурированными и полуструктурированными данными.

Были проведены исследования по определению стадий злокачественности [21, 22] и дифференциальной диагностике серозной карциномы высокой и низкой степени [23]. L. Qian и соавт. использовали многовариантную модель логистической регрессии в сочетании с МРТ-моделью радиомики, классической и комбинированной моделями [21]. Показано, что традиционная модель наиболее эффективна в выявлении различий между новообразованиями стадий I–II злокачественности, что является ключевым моментом в предоперативной диагностике рака яичников, ведь стадия злокачественности напрямую коррелирует с предполагаемым объемом и методом лечения.

Помимо ранее перечисленных моделей использовалась глубокая модель машинного обучения [24, 25]. F. Christiansen и соавт. проанализировали применение метода глубокого машинного обучения в дифференциальной диагностике рака яичников на основе приведенных УЗ-изображений [24]. Исходя из результатов данного исследования, можно сделать вывод, что модель глубокого обучения способна выявлять злокачественное новообразование с диагностической точностью, сравнимой с таковой мануального метода (анализ изображения врачом-экспертом), но с меньшими временными затратами. Помимо анализа изображений существуют методы, основанные на обнаружении биомаркеров-предикторов рака яичников. Например, F. Hamidi и соавт. [26] использовали регрессию Лассо и эластичную сетчатую регрессию для выявления типов микроРНК, характерных для рака яичников.

Применение искусственного интеллекта как предиктора эффективности лечения рака яичников

На данный момент можно определить опухоли яичников, которые дают положительный ответ на те-

рапию ингибиторами поли(АДФ-рибоза)-полимеразы, модуляторами гормональных рецепторов, ингибиторами контрольных точек. Возможно также выявление опухолей, резистентных и чувствительных к препаратам платины. Диагностируют наличие дефицита гомологичной рекомбинации, мутаций BRCA1 и BRCA2 соматических генов и генов зародышевой линии. ИИ может быть использован в целях обнаружения предикторов эффективности химиотерапии, ингибиторов поли(АДФ-рибоза)-полимеразы. При этом определить эффективность бевацизумаба при раке яичников на данный момент невозможно [27].

S. Negro и соавт. применяли модель глубокого машинного обучения classify the whole slide (CLAM) совместно с методом whole slide imaging для выявления мутации в генах BRCA1/2 [28]. С учетом наличия/отсутствия дефекта указанных генов онкологи подбирают терапию.

J. Ma и соавт. описали применение модели в качестве предиктора эффективности химиотерапии препаратами платины при раке яичников [29]. Использовалась нормальная логистическая модель регрессии для анализа представленных параметров (возраст, размер опухоли, стадия по FIGO и т.д.), которые в дальнейшем включались в анализ, проводимый с помощью мультивариантной модели регрессии. Показано, что стадия по FIGO, класс, количество циркулирующих опухолевых клеток и уровень СА-125 – независимые факторы в прогнозировании исхода лечения рака яичников.

Применение искусственного интеллекта в диагностике рака молочной железы

Модели машинного обучения и радиомику можно применять и для дифференциальной диагностики новообразований молочной железы. Именно раннее выявление онкологического заболевания способно предотвратить его прогрессирование и повысить шансы на эффективность терапии [30]. На данный момент используются различные методы скрининга рака молочной железы: маммография, МРТ, КТ, УЗИ. K.E. Oh и соавт. в 2023 г. опубликовали метаанализ, в котором описали применение радиомики для дифференциальной диагностики образований молочной железы [31]. На текущий момент золотым стандартом выявления типа новообразования молочной железы является биопсия. На основании результатов данного метаанализа можно сделать вывод, что применение радиомики в качестве неинвазивного метода первой линии скрининга позволяет извлечь количественные характеристики опухоли и провести ее послойный анализ. В дальнейшем это может ускорить процесс определения типа исследуемой опухоли. Еще одним преимуществом радиомики является возможность обнаружения редких, трудно диагностируемых типов рака молочной железы, например инвазивного микропапиллярного рака, с более точным определением глубины инвазии [32]. Применение ИИ помогает выявить вовлечение

лимфатических узлов в процесс метастазирования. Y.-L. Tang и соавт. использовали модель глубокого машинного обучения для обнаружения метастазов в подмышечных лимфатических узлах на основании анализа УЗ-изображений [33]. Одновременно с автоматической детекцией метастазов два специалиста вручную оценивали состояние лимфатических узлов. Установлено, что ИИ с большей точностью определяет наличие патологических образований ($p < 0,05$). Кроме того, машинное обучение помогает хирургам-онкологам определиться с объемом оперативного вмешательства.

J. Ma и соавт. сгенерировали модель для определения иммунного окружения опухоли, чтобы решить вопрос о проведении органосохраняющей операции [34]. ИИ выявляет положительные и отрицательные края резекции, что помогает установить степень риска (высокая, низкая) подобного оперативного вмешательства.

Применение искусственного интеллекта в качестве предиктора эффективности лечения рака молочной железы

Рак молочной железы – крайне гетерогенное заболевание. Подобрать адекватную терапию непросто, это кропотливый и трудоемкий процесс. Разные фенотипы опухолей неодинаково реагируют на цитотоксические агенты, которые считаются главными составляющими лечения рака молочной железы. С помощью ИИ можно прогнозировать результаты ПЦР-диагностики до начала неoadъювантной химиотерапии. Это может помочь онкологам максимально персонализировать применяемые схемы лечения и повысить ответ на лечение [35].

L. Stetson и соавт. описали применение мультиномики в совокупности с алгоритмами машинного обучения (random forest; support vector machines – метод опорных векторов) в качестве предиктора результативности химиотерапии таксаном при раке молочной железы [36].

Применение искусственного интеллекта в диагностике дисплазии и рака шейки матки

Модели ИИ применяются при диагностике рака шейки матки и внутриэпителиальной неоплазии шейки матки. С помощью машинного обучения оцениваются результаты кольпоскопии, МРТ, КТ, цитологического исследования шейки матки.

Опубликовано множество исследований, посвященных применению машинного обучения в кольпоскопии в процессе скрининга рака шейки матки. Например, Р. Хуе и соавт. проанализировали эффективность работы ИИ в отношении ручной расшифровки специалистами 19 000 кольпоскопических образцов [37]. Показано, что метод машинного обучения в 82,2% случаев (мануальный скрининг – 65,9%) выявляет аномальную кольпоскопическую картину (АКК), показывая при этом минимальные ложноположительные результаты. Помимо выявления дисплазии средней (CIN II) и тяжелой степени

(CIN III) была построена шкала рисков (какие пациентки в большей степени подвержены предраковым заболеваниям), а также описан процесс подбора места прицельной биопсии шейки матки при условии нормальной кольпоскопической картины у пациенток с положительным ВПЧ высокого онкогенного типа и LSIL/HSIL в мазках на онкоцитологию из шейки матки.

Р. Хуе и соавт. применяли модель глубокого машинного обучения (U-Net, YOLO) для выявления АКК [38]. С помощью ИИ были проанализированы изображения, полученные с использованием кольпоскопа, у 19 435 пациенток. Помимо выявления HSIL/LSIL степеней были предложены участки, из которых предполагался забор материала на биопсию. Достоверность результатов, полученных на основании диагностики изображений с помощью модели машинного обучения, оказалась выше, чем достоверность традиционного анализа изображений специалистами (82,2 против 65,9%). Однако остаются сложности с дифференциальной диагностикой стадий патологического процесса шейки матки.

Учитывая результаты исследований, можно предположить, что применение машинного обучения в кольпоскопии снизит количество ложноположительных результатов и сократит время врачей на выявление АКК. Однако на данный момент не разработано таких алгоритмов, которые полностью самостоятельно могли бы проводить дифференциальную диагностику патологических процессов шейки матки с указанием точной стадийности процесса.

Помимо рутинного анализа данных, полученных при кольпоскопии, в 2017 г. был разработан новый алгоритм – цервикография с применением Fast R-CNN для выявления аномальных клеток экзоцервикса после предварительной фокусировки оптического прибора на определенном участке шейки матки с точностью до 91% [38]. Вместе с тем данная модель глубокого машинного обучения была построена таким образом, что объединяла дисплазию средней и тяжелой степени (CIN II, CIN III), а также рак шейки матки в единую группу. Поэтому проводить дифференциальную диагностику предраковых состояний и рака с помощью данного алгоритма не представляется возможным. Следует отметить, что цервикография – метод, который не применяется в рутинной практике в странах с высоким уровнем развития медицины.

Применение ИИ при анализе цитологических мазков из шейки матки, как и при машинном анализе любых изображений, предполагает пять этапов: получение изображения, предварительную обработку, сегментацию, выделение клеточного ядра и цитоплазмы, извлечение признаков, а также их классификацию. Машинное обучение применяется на этапах сегментации и классификации для автоматического анализа мазков, что помогает повысить эффективность скрининга.

F.H. Araújo и соавт. применяли ИИ для дифференциальной диагностики LSIL или ASCUS стадий, используя изображения клеток шейки матки, полученные

после проведения PAP-теста [39]. Однако подобный метод требовал мануальной ассистенции для обнаружения и получения изображений отдельных клеточек. В свою очередь С.-W. Wang и соавт. разработали алгоритм на основе глубокого машинного обучения по автоматическому анализу HSIL стадии и рака шейки матки с использованием техники whole slide imaging [40].

Говоря об эффективности ИИ при анализе цитологической картины шейки матки, можно предположить, что технология машинного обучения способна с высокой точностью выявлять поражение стадии HSIL и выше. За короткий период времени автоматизированная система способна выявлять и маркировать атипичные клетки. Это призвано помочь цитологам быстрее проводить скрининг дисплазии шейки матки тяжелой степени. Однако существуют и ограничения. ИИ не выявляет атипичные клетки на размытых участках изображения. Если резкость и четкость изображения в области анализируемой клетки снижены или одна клетка перекрывает другую, программа с трудом проводит скрининг данного элемента. Поэтому сегодня автономно (без привлечения цитологов) проводить скрининг дисплазии и рака шейки матки на основании PAP-теста невозможно.

Применение искусственного интеллекта в диагностике синдрома поликистозных яичников

ИИ используется не только для диагностики онкологических заболеваний или как предиктор результативности лечения. ИИ применяется и на этапах выявления гинекологических эндокринопатий. Так, в настоящее время ИИ активно внедряется в процесс диагностики синдрома поликистозных яичников (СПКЯ) [41]. С помощью ИИ анализируются УЗ-изображения [42, 43], физикальные и гормональные параметры [43–45], экспрессируемые ДНК и РНК [46, 47]. Впоследствии делается вывод о наличии/отсутствии у пациенток данной патологии.

В настоящее время чаще применяются модели машинного обучения для анализа предполагаемого диагноза СПКЯ на основе УЗ-изображений. Однако из-за возможной нечеткой визуализации яичников в ходе УЗИ и человеческого фактора на этапе интерпретации результатов исследования разрабатываются новые методы анализа инструментальных и лабораторных данных пациенток с подозрением на СПКЯ.

Способы применения ИИ в диагностике СПКЯ, исходя из результатов УЗ-исследований, можно разделить на две группы:

- 1) автоматизированная обработка изображений с последующей сегментацией, выделением ключевых признаков и классификацией предварительно обработанных изображений;
- 2) метод глубокого машинного обучения на основании предоставленных УЗ-изображений в отсутствие этапа обработки, который хотя и достигает высокого уровня точности в анализе и классифи-

кации изображений, но имеет ограничение – существенные временные затраты на обучение и вычисления.

Соответственно внедрение изолированной техники глубокого машинного обучения в повседневную врачебную и диагностическую практику не совсем целесообразно [48]. При диагностике СПКЯ необходимо обратить внимание на расширенное машинное обучение.

S. Suha и соавт. изучали различия четырех типов машинного обучения в постановке данного диагноза [49]. Они сравнили обычную технику машинного обучения (анализ УЗ-изображения, классификация проанализированного изображения с использованием наивного байесовского классификатора, модели дерева решений, модели опорных векторов и метода k-ближайших соседей), обычную технику машинного обучения с уменьшением признаков (определяется оптимальный и сокращенный набор признаков из заданного изображения после его предварительной обработки методом главных компонент и автоматического установления взаимодействий Chi-square), технику глубокого обучения (анализ изображения с проведением тонкой настройки слоев) и расширенную технику (комбинация глубокого машинного обучения и стекинга – алгоритм ансамблирования). Согласно результатам данного исследования, два первых метода, основанных на традиционных алгоритмах машинного обучения, гораздо менее эффективны, в частности из-за большого количества признаков, анализируемых на УЗ-изображении или выявляемых для их последующего сокращения. Третий метод, в основе которого лежит глубокое машинное обучение, требует больше времени для вычислительных манипуляций. Гибридный метод обеспечивает максимальную точность – 99,89%. При этом временные затраты на выполнение анализа относительно небольшие. Однако одного изучения УЗ-снимков при постановке диагноза СПКЯ недостаточно. Гиперандрогения, нарушение менструального цикла, поликистоз – триада симптомов, которые должны быть выявлены для постановки данного диагноза [50]. При учете только результатов УЗИ диагноз СПКЯ неправилен.

Неверные интерпретации данных искусственным интеллектом

Несмотря на все преимущества и удобства использования ИИ, необходимо помнить, что ИИ не заменит врача. Применение ИИ требует соблюдения этики и конфиденциальности, что и является одной из самых больших проблем. Для обучения алгоритмов ИИ необходимы высококачественные данные, которые зачастую недоступны.

Как уже отмечалось, несмотря на все преимущества, ИИ способен совершать ошибки и не дает стопроцентной гарантии адекватности анализа и последующего результата. Поэтому ИИ не может полностью заменить оценку врачей.

В многочисленных исследованиях, в частности мета-анализах, авторы рекомендуют обращать внимание на процент эффективности и чувствительности моделей машинного обучения в предварительной постановке диагноза. Исследователи не отрицают, что нередко классические методы диагностики преобладают над стремительно развивающимися моделями машинного обучения. Так, в PubMed мы обнаружили статью А.К. Clift и соавт., в которой сравнивали эффективность машинного обучения и регрессионных методов для разработки модели, способной оценить десятилетний риск смертности от рака молочной железы любой стадии [51]. В популяционном когортном исследовании участвовали 141 765 женщин в возрасте 20 лет и старше с диагнозом инвазивного рака молочной железы (период – с 1 января по 31 декабря 2020 г.). Среди методов машинного обучения в исследовании использовались XGBoost и искусственная нейронная сеть. Регрессионный подход заключался в применении регрессии пропорциональных рисков Кокса и конкурирующих рисков. Модель оценивали с помощью внутренней/внешней перекрестной валидации. Для оценки производительности модели, транспортабельности и клинической ценности использовали метаанализ случайных эффектов, объединяющий оценки показателей дискриминации и калибровки, калибровочные графики и анализ кривой принятия решений [51]. Анализ кривой принятия решений показал, что модели регрессии Сох и конкурирующих рисков имеют более высокую клиническую ценность, чем упомянутые выше модели машинного обучения. Метод XGBoost, как и нейросетевые подходы, показал неустойчивую калибровку по группам стадий рака, особенно при опухолях стадий III–IV. По мнению авторов данного исследования, машинное обучение не всегда является самым эффективным и точным методом диагностики злокачественных новообразований [51].

На неверные интерпретации ИИ указывают Н.С. Dong и соавт. [52]. Исследователи проверяли точность ИИ при определении глубины инвазии миометрия методом глубокого обучения на МР-изображениях. Авторы получили 4896 увеличенных контрастом T1-взвешенных изображений (T1w) и T2-взвешенных изображений (T2w) от 72 пациенток с диагнозом патологической карциномы эндометрия стадии I. Изображения 24 (33,3%) пациенток использовались для обучения ИИ, а изображения 48 (66,7%) – для оценки точности модели. В качестве ИИ применялась глубокая нейронная сеть U-Net. ИИ проанализировал все случаи и отсортировал их по стадиям IA и IB. Про-

центный уровень точности интерпретации ИИ при T1w с контрастированием был выше (79,2%), при T2w – ниже (70,8%). Точность диагноза, предпологаемого рентгенологами, составила 77,8%. Несмотря на успех применения ИИ, авторы пришли к выводу, что наличие у пациенток сопутствующей лейомиомы создает препятствие для ИИ в точной диагностике степени инвазии миометрия. Именно по этой причине ИИ с большой долей вероятности неверно интерпретировал данные по сравнению с оценкой рентгенологов. Подобную ошибку в анализе авторы объяснили так: опухоль способна сдавливать миометрий, что в свою очередь приводит к нечетким границам между опухолью и миометрием. Это явно усложняет расчет глубины инвазии для ИИ. Таким образом, несмотря на все преимущества и удобства использования ИИ, он не всегда ставит точный диагноз [52].

Заключение

В цифровую эпоху ИИ заслуживает пристального внимания во всех сферах медицины. Применение ИИ открывает новые возможности в диагностике различных заболеваний. В настоящее время ИИ широко применяется в гинекологии, а именно в диагностике рака яичников, молочной железы, дисплазии и рака шейки матки, синдрома поликистозных яичников. ИИ не только помогает врачам в постановке диагноза, но и позволяет определить точную стадию процесса, что в свою очередь облегчает врачам-экспертам выбор тактики лечения, а также значительно снижает количество врачебных ошибок.

ИИ подразумевает использование компьютерных технологий для создания модели разумного поведения с минимальным вмешательством человека. Однако, несмотря на огромный потенциал ИИ, а также учитывая результаты многочисленных исследований, можно сделать вывод, что сегодня ИИ не может заменить врача. Риск ошибок при использовании компьютерных технологий не исключен, хотя и маловероятен. Не стоит забывать, что ИИ решает только ту задачу, которой обучен. Иными словами, ИИ применяется в определенных границах. ИИ также способен совершать ошибки и выдавать неправильные результаты.

Изучение возможностей ИИ – одна из актуальнейших тем. И пока ИИ находится в стадии активного изучения, не стоит пренебрегать синергизмом ИИ и врачей.

*Авторы заявляют
об отсутствии конфликта интересов.*

Литература

1. Dhombres F, Bonnard J, Bailly K., et al. Contributions of artificial intelligence reported in obstetrics and gynecology journals: systematic review. J. Med. Internet. Res. 2022; 24 (4): e35465.
2. Dembrower K., Crippa A., Colón E., et al. Artificial intelligence for breast cancer detection in screening mammography in Sweden: a prospective, population-based, paired-reader, non-inferiority study [published correction appears in Lancet Digit Health. 2023 Oct; 5 (10): e646]. Lancet Digit. Health. 2023; 5 (10): e703–e711.
3. Louis J., Muhlenberg G., Verbeke G., et al. A machine model of support vectors using the least squares method with mixed effects for the classification of longitudinal data. Computational Statistics and Data Analysis. 2012; 56 (3): 611–628.

4. Xiong Y., Kim H.J., Singh V. Mixed Effects Neural Networks (MeNets) With Applications to Gaze Estimation, 2019 IEEE/ CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019; 7735–7744.
5. Neuhaus J.M. Statistical methods for longitudinal and clustered designs with binary responses. *Stat. Methods Med. Res.* 1992; 1 (3): 249–273.
6. Ciampi A., Lin Q., Yousif G. GLIMTREE: RECPAM Trees with the Generalized Linear Model. In: Momirović K., Mildner V. (eds). *Compstat. Physica-Verlag HD*.
7. Aertsen W., Kint V., De Vos B., et al. Predicting forest site productivity in temperate lowland from forest floor, soil and litterfall characteristics using boosted regression trees. *Plan Soil.* 2012; 354: 157–172.
8. Sammel M., Lin X., Ryan L. Multivariate linear mixed models for multiple outcomes. *Stat. Med.* 1999; 18 (17–18): 2479–2492.
9. Eo S.-H., Cho H.J. Tree-structured mixed-effects regression modeling for longitudinal data. *Journal of Computational and Graphical Statistics.* 2014; 23 (3): 740–760.
10. Fokkema M., Smits N., Zeileis A., et al. Detecting treatment-subgroup interactions in clustered data with generalized linear mixed-effects model trees. *Behav. Res. Methods.* 2018; 50 (5): 2016–2034.
11. Lohrmann D., Jayawardene W., Torabi M. Factors associated with changes in fruit intake during young adulthood: a classification and regression tree analysis of longitudinal data. *J. Nutr. Educ. Behav.* 2017; 49 (5): 427–434.e1.
12. Shrestha P., Poudyal B., Yadollahi S., et al. A systematic review on the use of artificial intelligence in gynecologic imaging – background, state of the art, and future directions. *Gynecol. Oncol.* 2022; 166 (3): 596–605.
13. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016; 770–778.
14. Chen X., Wang X., Zhang K., et al. Recent advances and clinical applications of deep learning in medical image analysis. *Med. Image Anal.* 2022; 79: 102444.
15. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature.* 2015; 521 (7553): 436–444.
16. Van Engelen J.E., Hoos H.H. A survey on semi-supervised learning. *Machine Learning.* 2020; 109 (2): 373–440.
17. Gao Y., Zeng S., Xu X., et al. Deep learning-enabled pelvic ultrasound images for accurate diagnosis of ovarian cancer in China: a retrospective, multicentre, diagnostic study. *Lancet Digit. Health.* 2022; 4 (3): e179–e187.
18. Hosny A., Parmar C., Quackenbush J., et al. Artificial intelligence in radiology. *Nat. Rev. Cancer.* 2018; 18 (8): 500–510.
19. Speiser J.L. A random forest method with feature selection for developing medical prediction models with clustered and longitudinal data. *J. Biomed. Inform.* 2021; 117: 103763.
20. Amidi E., Mostafa A., Nandy S., et al. Classification of human ovarian cancer using functional, spectral, and imaging features obtained from in vivo photoacoustic imaging. *Biomed. Opt. Express.* 2019; 10 (5): 2303–2317.
21. Qian L., Ren J., Liu A., et al. MR imaging of epithelial ovarian cancer: a combined model to predict histologic subtypes. *Eur. Radiol.* 2020; 30 (11): 5815–5825.
22. Li J., Li X., Ma J., et al. Computed tomography-based radiomics machine learning classifiers to differentiate type I and type II epithelial ovarian cancers. *Eur. Radiol.* 2023; 33 (7): 5193–5204.
23. An H., Wang Y., Wong E.M.F., et al. CT texture analysis in histological classification of epithelial ovarian carcinoma. *Eur. Radiol.* 2021; 31 (7): 5050–5058.
24. Christiansen F., Epstein E.L., Smedberg E., et al. Ultrasound image analysis using deep neural networks for discriminating between benign and malignant ovarian tumors: comparison with expert subjective assessment. *Ultrasound Obstet. Gynecol.* 2021; 57 (1): 155–163.
25. Wang R., Cai Y., Lee I.K., et al. Evaluation of a convolutional neural network for ovarian tumor differentiation based on magnetic resonance imaging. *Eur. Radiol.* 2021; 31 (7): 4960–4971.
26. Hamidi F., Gilani N., Belaghi R.A., et al. Exploration of potential miRNA biomarkers and prediction for ovarian cancer using artificial intelligence. *Front. Genet.* 2021; 12: 724785.
27. Colombo N., Sessa C., du Bois A., et al. ESMO-ESGO consensus conference recommendations on ovarian cancer: pathology and molecular biology, early and advanced stages, borderline tumours and recurrent disease. *Ann. Oncol.* 2019; 30 (5): 672–705.
28. Nero C., Boldrini L., Lenkiewicz J., et al. Deep-learning to predict BRCA mutation and survival from digital H&E slides of epithelial ovarian cancer. *Int. J. Mol. Sci.* 2022; 23 (19): 11326.
29. Ma J., Yang J., Jin Y., et al. Artificial intelligence based on blood biomarkers including CTCs predicts outcomes in epithelial ovarian cancer: a prospective study. *Onco Targets Ther.* 2021; 14: 3267–3280.
30. Адамян Л.В., Родионов В.В., Шешко Е.Л., Долгушина Н.В. Лоброкачественная дисплазия молочной железы с позиции BI-RADS: современный взгляд на проблему. *Проблемы репродукции.* 2023; 29 (5): 119–124.
31. Oh K.E., Vasandani N., Anwar A. Radiomics to differentiate malignant and benign breast lesions: a systematic review and diagnostic test accuracy meta-analysis. *Cureus.* 2023; 15 (11): e49015.
32. Verras G.I., Tchabashvili L., Mulita F., et al. Micropapillary breast carcinoma: from molecular pathogenesis to prognosis. *Breast Cancer (Dove Med. Press).* 2022; 14: 41–61.
33. Tang Y.L., Wang B., Ou-Yang T., et al. Ultrasound radiomics based on axillary lymph nodes images for predicting lymph node metastasis in breast cancer. *Front. Oncol.* 2023; 13: 1217309.
34. Ma J., Chen K., Li S., et al. MRI-based radiomic models to predict surgical margin status and infer tumor immune microenvironment in breast cancer patients with breast-conserving surgery: a multicenter validation study. *Eur. Radiol.* 2023.

35. Tran W.T., Jerzak K., Lu F.I., et al. Personalized breast cancer treatments using artificial intelligence in radiomics and pathomics. *J. Med. Imaging Radiat. Sci.* 2019; 50 (4 Suppl 2): S32–S41.
36. Computational identification of multi-omic correlates of anticancer therapeutic response. *BMC Genomics.* 2014; 15 (Suppl 7): S2.
37. Xue P, Tang C., Li Q., et al. Development and validation of an artificial intelligence system for grading colposcopic impressions and guiding biopsies. *BMC Med.* 2020; 18 (1): 406.
38. Wang P, Wang L., Li Y., et al. Automatic cell nuclei segmentation and classification of cervical Pap smear images. *Biomed. Signal Process. Control.* 2019; 48: 93–103.
39. Araújo F.H., Silva R.R.V., Ushizima D.M., et al. Deep learning for cell image segmentation and ranking. *Comput. Med. Imaging Graph.* 2019; 72: 13–21.
40. Wang C.W., Liou Y.A., Lin Y.J., et al. Artificial intelligence-assisted fast screening cervical high grade squamous intraepithelial lesion and squamous cell carcinoma diagnosis and treatment planning. *Sci. Rep.* 2021; 11 (1): 16244.
41. Barrera F.J., Brown E.D.L., Rojo A., et al. Application of machine learning and artificial intelligence in the diagnosis and classification of polycystic ovarian syndrome: a systematic review. *Front. Endocrinol.* 2023; 14: 1106625.
42. Nazarudin A.A., Zulkarnain N., Mokri S.S., et al. An implementation of Otsu thresholding and the Chan–Vese method on the PCO segmentation of ultrasound images. In: 2020 2nd International Conference on Electrical, Control and Instrumentation Engineering (ICECIE), 2020; 1–9.
43. Gopalakrishnan C., Iyapparaja M. Multilevel thresholding based follicle detection and classification of polycystic ovary syndrome from the ultrasound images using machine learning. *Int. J. System Assur. Eng. Manage.* 2021.
44. Prapty A.S., Shitu T.T. An efficient decision tree establishment and performance analysis with different machine learning approaches on polycystic ovary syndrome. 2020. 23rd International Conference on Computer and Information Technology (ICCIT), DHAKA, Bangladesh, 2020; 1–5.
45. Vedpathak S., Thakre V. PCOCare: PCOS detection and prediction using machine learning algorithms. *Biosci. Biotechnol. Res. Commun.* 2020; 13: 240–244.
46. Ho C.H., Chang C.M., Li H.Y., et al. Dysregulated immunological and metabolic functions discovered by a polygenic integrative analysis for PCOS. *Reprod. BioMed. Online.* 2020; 40 (1): 160–167.
47. Dapas M., Lin F.T.J., Nadkarni G.N., et al. Distinct subtypes of polycystic ovary syndrome with novel genetic associations: an unsupervised, phenotypic clustering analysis. *PLoS Med.* 2020; 17 (6): e1003132.
48. Zhou Z., Liao H., Gu B., et al. Robust mobile crowd sensing: when deep learning meets edge computing. *IEEE Network.* 2018; 32 (4): 54–60.
49. Suha S.A., Islam M.N. An extended machine learning technique for polycystic ovary syndrome detection using ovary ultrasound image. *Sci. Rep.* 2022; 12 (1): 17123.
50. Fauser B.C., Tarlatzis B.C., Rebar R.W., et al. Consensus on women's health aspects of polycystic ovary syndrome (PCOS): the Amsterdam ESHRE/ASRM-Sponsored 3rd PCOS Consensus Workshop Group. *Fertil. Steril.* 2012; 97 (1): 28–38.e25.
51. Clift A.K., Dodwell D., Lord S., et al. Development and internal-external validation of statistical and machine learning models for breast cancer prognostication: cohort study. *BMJ.* 2023; 381: e073800.
52. Dong H.C., Dong H.K., Yu M.H., et al. Using deep learning with convolutional neural network approach to identify the invasion depth of endometrial cancer in myometrium using MR images: a pilot study. *Int. J. Environ Res. Public Health.* 2020; 17 (16): 5993.

Artificial Intelligence in Diagnostic and Treatment of Gynecological Diseases

L.V. Adamyan, PhD, Prof., Academician of RASci^{1,2}, Ye.V. Sibirskaya, PhD, Prof.^{1,3,4}, L.G. Pivazyan², S.G. Isaeva⁵, S.K. Murvatova⁵, Ye.D. Nakhapetyan⁴

¹ Russian University of Medicine

² Academician V.I. Kulakov National Medical Research Center for Obstetrics, Gynecology and Perinatology

³ Russian Children's Clinical Hospital – a Branch of N.I. Pirogov Russian National Research Medical University

⁴ N.I. Pirogov Russian National Research Medical University

⁵ I.M. Sechenov First Moscow State Medical University

Contact person: Yelena V. Sibirskaya, elsibirskaya@yandex.ru

Artificial intelligence (AI) is being introduced into healthcare system as a synergist and assistant to practitioners. AI is used at all stages of the diagnostics for various gynecological diseases, helps to generate the most effective treatment strategy and analyze therapy outcomes. This review examines data on artificial intelligence usage in gynecology. The general characteristics of the types of artificial intelligence are presented. The effectiveness of various machine learning methods in diagnosis and treatment of breast, cervix, and ovaries pathology is discussed.

Keywords: artificial intelligence, diagnostics, therapy, gynecology