КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ СИСТЕМЫ ДИАГНОСТИКИ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ НА ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Мухамедиева Дилдора Кабилжановна[1], Дошанова Малика Юлдашовна[2], Шаазизова Мадина Элдаровна[2], Бекимбетова Дурдона Икромжон кизи[3], Авезжанов Бобур Жамалович[4]

[1]ТУИТ имени Мухаммада ал-Хоразмий, профессор,
[2]ТУИТ имени Мухаммада ал-Хоразмий, доцент
[3]ТУИТ имени Мухаммада Ал-Хоразмий, магистр,
[4]ТУИТ имени Мухаммада ал-Хоразмий, студент

K E Y W O R D S

рак молочной железы, маммография, искусственный интеллект, глубокое обучение, компьютерное моделирование, имитационная модель, система поддержки принятия решений

A B S T R A C T

В статье рассматриваются принципы компьютерного моделирования системы диагностики рака молочной железы на основе технологий искусственного интеллекта и машинного обучения. Формализуется задача моделирования скринингового потока пациенток, описывается архитектура ИИ-модуля анализа маммографических данных, предлагается имитационная модель интеграции алгоритмов глубокого обучения в контуре «врач–машина». Приводятся рекомендации по построению вычислительного эксперимента, анализу показателей эффективности и сравнительной оценке различных организационных схем скрининга.

Введение

Рак молочной железы (РМЖ) остаётся ведущей причиной онкологической смертности среди женщин во всём мире. Раннее выявление за счёт организованного маммографического скрининга позволяет существенно снизить смертность, однако эффективность традиционных программ ограничена рядом факторов: вариабельностью интерпретации снимков, высокой нагрузкой на радиологов, значительной долей ложноположительных и ложноотрицательных результатов.

Развитие методов глубокого обучения и компьютерного зрения привело к созданию систем искусственного интеллекта (ИИ), способных достигать и даже превосходить уровень экспертов-радиологов в задаче детекции и классификации рака молочной железы по маммограммам и томосинтезу [1]. Одним из знаковых примеров является ИИ-система Google Health, продемонстрировавшая более высокий показатель AUC-ROC по сравнению с группой радиологов и снижении числа ложных решений в условиях реальных скрининговых программ [2].

Однако внедрение таких систем в клиническую практику требует не только разработки алгоритмов, но и компьютерного моделирования всей диагностической цепочки: от потока пациенток и структуры данных до поведения врачей и организационных схем чтения (одинарное/двойное чтение, ИИ как «второй читатель» и т.п.). Именно на уровне моделирования можно оценить потенциальный эффект от применения ИИ – по снижению смертности, уменьшению числа повторных вызовов, оптимизации ресурсов и др., не подвергая пациенток риску в реальном эксперименте.

Цель настоящей работы – описать концептуальные и математические основы компьютерного моделирования системы диагностики РМЖ на основе ИИ и показать, как на основе моделирования можно сравнивать различные варианты архитектуры и интеграции ИИ в клинический процесс.

© Д.Мухамедиева, М.Дошанова, М.Шаазизова, Д.Бекимбетова, Б.Авезжанов

Проведенные исследования в области систем искусственного интеллекта для диагностики рака молочной железы

Последние годы стали периодом интенсивного развития научных исследований, посвящённых применению искусственного интеллекта в диагностике рака молочной железы. На международной арене доминируют крупные исследовательские консорциумы, объединяющие технологические компании, медицинские учреждения и академические институты. Наиболее известным примером является серия работ Google Health, в которых были представлены модели глубокого обучения, способные воспроизводить и даже превосходить решения специалистов-радиологов в задачах интерпретации маммограмм. Эти исследования использовали масштабные мультинациональные базы данных, что позволило достичь высокой обобщающей способности моделей и устойчивости к межрегиональным различиям в визуализации [3,4].

Большой вклад внесли работы Mayo Clinic и RadImageNet, предложившие концепцию специализированных медицинских датасетов, обученных именно на радиологических изображениях, а не на обычных фотографиях. Это существенно повысило качество моделей и показало, что адаптация архитектур ИИ к медицинским данным – ключевой фактор успеха [5,6].

Значительную роль играют исследования архитектур Vision Transformer, которые благодаря механизму самовнимания позволяют моделировать контекстные зависимости в изображениях молочной железы [7]. Такие модели успешно применяются как в классической цифровой маммографии (2D), так и в цифровой томосинтезной маммографии (3D DBT), демонстрируя высокую чувствительность при выявлении малоразмерных и слабоконтрастных образований.

Регион Центральной Азии, включая Узбекистан, в последние годы формирует собственную научную базу в области ИИ-диагностики. Публикации исследовательских групп затрагивают задачи адаптации глубоких моделей к локальным данным, создания аннотированных выборок маммограмм, обучения моделей на ограниченных и неоднородных данных, а также применения explainable AI для повышения доверия врачей. Исследователи отмечают необходимость построения локальных PACS-архивов, разработки собственных датасетов и реализации пилотных проектов по интеграции ИИ в систему онкологической диагностики [8].

Таким образом, международные и республиканские исследования объединяет стремление повысить качество диагностики с помощью ИИ, но в локальном контексте перед исследователями стоят дополнительные задачи: адаптация к специфике оборудования, малым данным и ограниченным ресурсам.

Технологии машинного обучения и искусственного интеллекта в диагностике рака молочной железы

Технологическая база современных систем диагностики рака молочной железы опирается на глубокие нейронные сети, обладающие высокой способностью к автоматизированному извлечению сложных структурных и текстурных признаков. Сверточные нейронные сети (CNN) остаются основной архитектурой, поскольку они наиболее эффективно моделируют локальные особенности маммографических изображений: микрокальцинаты, спикулированные контуры, асимметрии плотности и другие морфологические маркеры опухолевого процесса. Такие архитектуры, как ResNet, DenseNet и EfficientNet, используются для классификации, а U-Net и её производные – для сегментации.

Современная тенденция – переход от чисто сверточных архитектур к трансформерным моделям. Vision Transformer (ViT) и его модификации демонстрируют превосходные результаты в задачах анализа крупных изображений высокого разрешения, характеризующихся сложной глобальной структурой. Их преимущество заключается в способности анализировать взаимосвязи между удаленными участками изображения, что особенно важно для оценки асимметрии

или диффузных изменений в ткани молочной железы.

Отдельное направление – радиомика, которая использует математически определяемые количественные признаки изображения для оценки гетерогенности опухоли, внутритканевых структур и текстурных закономерностей. Радиомика стала связующим звеном между визуализацией и биологией опухоли, позволяя прогнозировать агрессивность, потенциал метастазирования и ответ на лечение [9-13].

Набирают популярность методы самообучения (Self-Supervised Learning), позволяющие эффективно обучать модели на больших неразмеченных архивах медицинских изображений, и технологии распределённого обучения (Federated Learning), обеспечивающие обучение без передачи данных между учреждениями.

Генеративные модели – GAN и Diffusion – используются для синтеза синтетических изображений, улучшения разрешения, устранения шумов, балансировки классов и моделирования редких клинических случаев, что существенно увеличивает устойчивость моделей к вариативности данных.

Таким образом, современная технологическая экосистема ИИ-диагностики рака молочной железы представляет собой совокупность взаимодополняющих методов, обеспечивающих высокую точность, адаптивность и интерпретируемость анализа медицинских изображений.

Постановка задачи компьютерного моделирования

Объектом моделирования в данном направлении считается система маммографического скрининга и диагностики рака молочной железы, включающая

- поток пациенток (первичный скрининг, повторные обследования);
- маммографическое оборудование (2D маммография, цифровая томосинтезная система DBT);
- радиологов и их решения;
- ИИ-модуль анализа изображений;
- последующие клинические действия (дополнительные исследования, биопсия, лечение).

А предмет моделирования является влияние внедрения ИИ-системы на диагностические показатели (чувствительность, специфичность, AUC-ROC, доля ложноположительных/ложноотрицательных результатов), организационные параметры (нагрузка на радиологов, время чтения, количество вторых чтений) и клинико-экономические эффекты.

Основные цели компьютерного моделирования системы диагностики рака молочной железы на основе искусственного интеллекта считается:

- количественная оценка эффективности ИИ в различных сценариях использования;
- сравнение схем:

1. «врач без ИИ»,
2. «ИИ как второй читатель»,
3. «ИИ как предварительный фильтр» (triage),
4. «ИИ + врач в режиме согласованного решения»;

- исследование влияния качества ИИ-модели (чувствительность, специфичность, пороги принятия решений) на результаты скрининга;
- оценка потенциального снижения числа пропущенных случаев РМЖ и ненужных биопсий;
- анализ робастности системы к изменению характеристик популяции (распределение возраста, плотности молочной железы, распространённость РМЖ).

В базовом варианте моделирования делаются следующие допущения:

- поток пациенток представляется пуассоновским или задаётся реальными статистическими данными скрининговой программы;
- истинное состояние пациентки (наличие/отсутствие РМЖ) моделируется на основе заданной распространённости заболевания;

- характеристики ИИ-модели и радиологов описываются матрицами ошибок (confusion matrices) или кривыми ROC/PR;
- решение о направлении на биопсию принимается по заданным порогам риска (для ИИ) и/или категоризации BI-RADS (для радиолога).

Архитектура ИИ-системы диагностики и её компьютерная модель

Функциональная архитектура интеллектуальной системы диагностики рака молочной железы представляет собой многоуровневую модульную структуру, в которой каждый компонент выполняет строго определённую задачу в процессе анализа медицинских изображений. Архитектура разработана таким образом, чтобы обеспечить последовательный поток данных – от первичного получения маммографических изображений до формирования диагностически значимой информации для врача-радиолога (Рис. 1).

Первый уровень включает модуль ввода данных, обеспечивающий получение изображений в стандарте DICOM напрямую из медицинских архивов PACS. На этом этапе выполняется автоматическая привязка клинических метаданных, включая возраст пациентки, плотность молочной железы и сведения анамнеза, что позволяет учитывать индивидуальные особенности в последующем анализе.

Следующим этапом является модуль предобработки, в котором проводится нормализация яркости и контраста, коррекция неоднородностей, устранение артефактов и геометрических искажений. Важной задачей данного модуля является выделение областей интереса (ROI), что позволяет сократить вычислительные затраты и повысить точность последующих алгоритмов.

Ключевым компонентом системы является модуль анализа изображений, который реализует алгоритмы глубокого обучения. Он включает подсистему сегментации, основанную на архитектурах U-Net и её модификациях, предназначенную для выделения анатомических структур и патологически изменённых областей. Подсистема детекции, основанная на моделях Faster R-CNN, YOLO и RetinaNet, выполняет локализацию подозрительных участков. Завершает анализ блок классификации, использующий сверточные сети, Vision Transformer или гибридные архитектуры для оценки вероятности наличия злокачественного процесса.

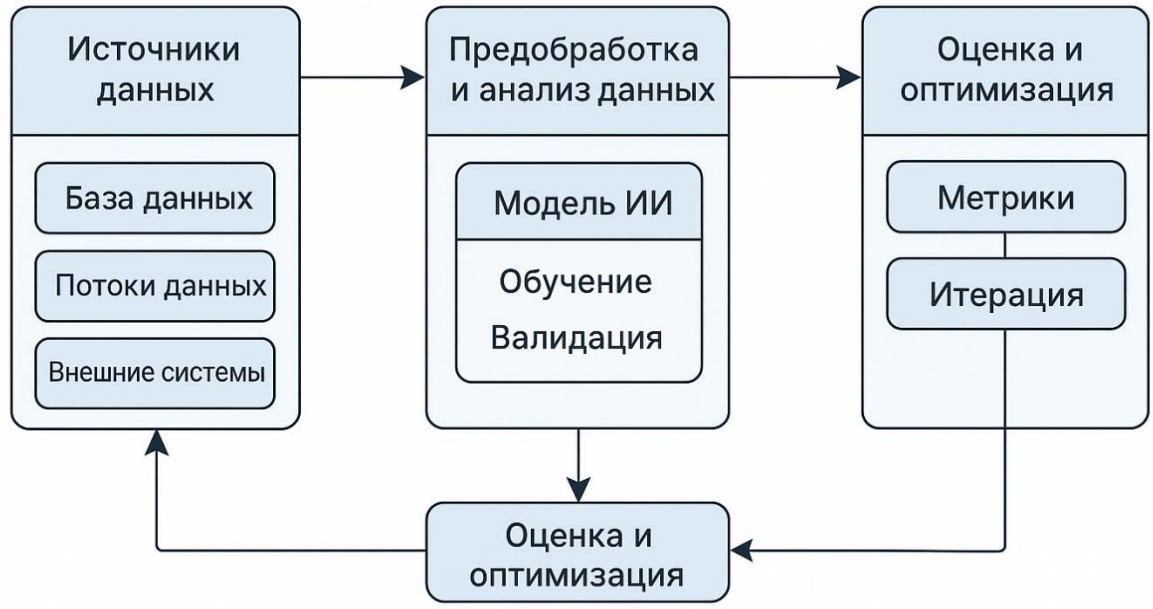


Рис. 1. Общая архитектура компьютерного моделирования ИИ-системы

© Д.Мухамедиева, М.Дошанова, М.Шаазизова, Д.Бекимбетова, Б.Авезжанов

Для интеграции результатов на уровне исследования предусмотрен модуль агрегации и стратификации риска, который объединяет данные по нескольким проекциям и формирует итоговый риск-скор. На основании вероятностных моделей формируется значение, аналогичное BI-RADS, что позволяет внедрить ИИ-решение в существующие клинические протоколы.

Важной частью архитектуры является модуль визуализации и объяснимости (Explainable AI). Он генерирует карты внимания – Grad-CAM, attention-карты и вероятностные распределения риска, что повышает прозрачность решения модели и способствует доверию радиологов. Также в рамках данного модуля формируются отчёты с визуальными и текстовыми пояснениями.

Завершающим компонентом является интеграционный интерфейс с клинической информационной системой, обеспечивающий двусторонний обмен данными с RIS/PACS, регистрацию решений врача и клинических исходов, а также накопление данных для последовательного дообучения модели. Этот модуль играет системообразующую роль, позволяя внедрить ИИ-алгоритм в реальный клинический процесс и обеспечить его непрерывное совершенствование.

Таким образом, представляемая функциональная архитектура является комплексной, модульной и адаптивной, обеспечивая реализацию полного цикла автоматизированного анализа маммографических данных и интеграцию ИИ-модулей в клинический рабочий процесс.

Математическое описание блока принятия решений

В компьютерной модели система представляется как набор классификаторов, действующих последовательно или параллельно:

- классификатор ***F_AI(x)*** – ИИ-модель, возвращающая вероятность *p_AI*(РМЖ|изображение *x*);
- классификатор ***F_doc(x)*** – модель поведения радиолога, описываемая эмпирически (по данным reader study) или заданная матрицей ошибок.

Решение о наличии заболевания в сценарии «ИИ как второй читатель» может моделироваться как:

$$D = g(F_{AI}(x), F_{doc}(x), \theta),$$

где g – правило агрегации (например, «ИЛИ»/«И», взвешенное усреднение, логистическая композиция), θ – пороги и веса.

Для сценария triage ИИ выполняет предварительное разделение потока на:

- низкий риск – исследование может быть пропущено радиологом или просматриваться ускоренно;
- высокий риск – приоритетное подробное чтение.

Имитационное моделирование скринингового процесса

Имитационная модель может быть реализована в парадигме дискретно-событийного моделирования. Основные сущности, которые используются в данной модели следующие:

- Пациентка – объект с атрибутами (возраст, риск, истинный статус РМЖ, плотность ткани, наличие симптомов).
- События:

1. приглашение на скрининг;
2. проведение маммографии;
3. анализ изображений (врач/ИИ);
4. направление на дополнительную визуализацию/биопсию;
5. установление диагноза;
6. дальнейшее наблюдение.

Для каждого сценария (без ИИ, ИИ как второй читатель, triage и т.п.) модель реализует различный порядок событий и правила принятия решений. Основные параметры модели, задаваемые пользователем:

- распространённость РМЖ в целевой популяции (например, 5–8 случаев на 1000 скрининговых обследований);

(cc) BY © Д.Мухамедиева, М.Дошанова, М.Шаазизова, Д.Бекимбетова, Б.Авезжанов

- чувствительность и специфичность ИИ-модели, радиологов и их комбинаций;
- распределения показателей качества в подгруппах (по плотности молочной железы, возрасту и др.);
- доля повторных вызовов при сомнительных результатах;
- вероятности следования рекомендациям (compliance) со стороны пациенток.

Модель после применения позволяет оценивать долю выявленных случаев РМЖ на ранних стадиях, количество ложноположительных и ложноотрицательных результатов, число дополнительных исследований и биопсий, нагрузку на радиологов (количество исследований/день, доля вторых чтений) и интегральные показатели, такие как AUC-ROC, AUPRC, PPV, NPV и др.

Сценарии компьютерного эксперимента

Сценарий 1: сравнение «без ИИ» и «ИИ как второй читатель»

В этом сценарии моделируется классическая схема двойного чтения: для части исследований вторым читателем выступает другой радиолог, для другой части – ИИ-система. Анализируется изменение чувствительности/специфичности, снижение доли повторных вызовов и сокращение нагрузки на второго врача (в ряде работ моделирование показало возможность уменьшения объёма второго чтения до 80–90%).

Сценарий 2: triage-фильтр на основе ИИ

Задача – исследовать, можно ли безопасно исключить часть снимков низкого риска из подробного рассмотрения радиологом. В компьютерном эксперименте задаётся порог p_AI, при котором исследования относится к «очевидно нормальным», оценивается доля снимков, которые можно пропустить и оценивается риск пропуска злокачественных образований в этой группе.

Такой сценарий особенно актуален для перегруженных систем скрининга и регионов с дефицитом кадров.

Сценарий 3: риск-ориентированный скрининг

На основе моделей долгосрочного риска (например, MIRAI, объединяющих маммографию и клинические факторы) моделируется переход от «одинакового интервала для всех» к индивидуализированным интервалам: высокорисковые пациентки проходят обследование чаще, низкорисковые – реже. Имитация позволяет оценить снижение числа поздних стадий при том же объёме ресурсов, изменение структуры нагрузки на маммографические кабинеты и потенциальный выигрыш по QALY/смертности.

Сценарий 4: многомодальные ИИ-системы

В этом сценарии ИИ-модуль объединяет данные 2D маммографии, DBT (цифровая томосинтезная маммография), ультразвук и клинические параметры. Модель позволяет оценить, насколько подключение дополнительных модальностей снижает неопределённость, уменьшает число ненужных биопсий и улучшает стратификацию риска.

Обсуждение результатов

Компьютерное моделирование системы диагностики РМЖ на основе ИИ играет роль «виртуальной лаборатории», где можно безопасно и относительно дёшево:

- апробировать новые алгоритмы ИИ до дорогостоящих и сложных клинических испытаний;
- тестировать организационные решения, не вмешиваясь в реальный рабочий процесс;
- учитывать особенности конкретной страны/региона (структура популяции, ресурсы, плотность сети маммографических кабинетов);
- оценивать чувствительность системы к ухудшению качества данных (например, к

(cc) BY

снижению качества изображений, смещению популяции).

Важное преимущество – возможность «поиграть» параметрами ИИ-модели: повышать или снижать чувствительность и специфичность, варьировать пороги решений, комбинировать ИИ с разными профилями радиологов. Это критично, поскольку реальные исследования показывают широкий разброс качества ИИ-систем и необходимость их адаптации к локальным данным. С другой стороны, имитационные модели имеют ограничения:

- зависят от корректности статистических предпосылок;
- могут не учитывать сложные поведенческие факторы (усталость врача, изменение стратегий при появлении ИИ);
- требуют качественных исходных данных для калибровки.

Поэтому компьютерное моделирование следует рассматривать как дополнение, а не замену клинических исследований: оно помогает сформировать гипотезы, оптимизировать дизайн будущих испытаний и заранее отсеять заведомо неэффективные варианты.

Заключение

Компьютерное моделирование системы диагностики рака молочной железы на основе искусственного интеллекта является ключевым инструментом для рационального и безопасного внедрения AI-технологий в клиническую практику. Предложенный подход, включающий формализацию скринингового процесса, описание архитектуры ИИ-модуля, имитационное дискретно-событийное моделирование и сценарный анализ различных схем интеграции ИИ, позволяет количественно оценить ожидаемый эффект от использования ИИ, сравнивать альтернативные организационные решения и адаптировать систему под условия конкретной страны или региона.

В дальнейшем развитие компьютерного моделирования может быть связано с использованием реалистичных моделей популяции и прогрессии заболевания (микросимуляции, модели на основе Марковских процессов), более детальной моделизацией поведения врачей и пациенток, включением экономического анализа (стоимость, cost-effectiveness, QALY) и интеграцией результатов моделирования в процесс разработки национальных программ скрининга и стратегий цифровой медицины.

Литература:

1. McKinney S.M. et al. International evaluation of an AI system for breast cancer screening. Nature. 2020; 577:89–94.
2. Wang L. et al. Mammography with deep learning for breast cancer detection: a review. BMC Cancer. 2024.
3. Amin A. et al. Deep learning-based CAD systems for breast cancer detection: a systematic review with focus on Asia. BMC Cancer. 2025.
4. Rahman M.A. Advancements in breast cancer detection: a review of AI and ML methods. Diagnostics. 2025.
5. Ali A. et al. Exploring AI approaches for breast cancer detection and diagnosis. Breast Cancer: Targets and Therapy. 2025.
6. Wang R. Deep Learning in Digital Breast Tomosynthesis. European Journal of Radiology. 2025.
7. Kassis I. et al. Detection of breast cancer in digital breast tomosynthesis using vision transformers. Scientific Reports. 2024.
8. Alashban Y. et al. Breast cancer detection and classification with digital breast tomosynthesis: a two-stage deep learning approach. Diagnostic and Interventional Radiology. 2024.
9. Yala A. et al. A deep learning mammography-based model for 5-year breast cancer risk prediction (MIRAI). Radiology. 2019.
10. Mota A.M. et al. AI-based characterization of breast cancer in multimodal imaging. Cancers. 2025.
11. Jeba Prasanna S. et al. Recent trends on mammogram breast density analysis using deep learning. Artificial Intelligence Review. 2025.
12. Shimokawa D. et al. Deep learning model for breast cancer diagnosis based on asymmetry detection. Journal of Medical Ultrasonics. 2023.
13. Sutjiadi R. Deep learning for segmentation and classification in mammography: a survey. AUDT. 2024.

(cc) BY © Д.Мухамедиева, М.Дошанова, М.Шаазизова, Д.Бекимбетова, Б.Авезжанов