



Исследования и разработки в области новых
информационных технологий и их приложений

<https://doi.org/10.25559/SITITO.021.202503.476-489>

УДК 004.89

Гибридная архитектура на основе ResNet-50, Vision Transformers и радиомики для интерпретируемой классификации микрокальцинатов в маммографии

Х. Алсаджер^{1*}, Ю. Н. Филиппович¹, Т. В. Бекетова²

Оригинальная статья

¹ ФГАОУ ВО «Московский политехнический университет», г. Москва, Российская Федерация

Адрес: 107023, Российская Федерация, г. Москва, ул. Большая Семёновская, д. 38

² ФГБУ «Центральная клиническая больница с поликлиникой» Управления делами Президента Российской Федерации, г. Москва, Российская Федерация

Адрес: 121359, Российская Федерация, г. Москва, ул. Маршала Тимошенко, д. 15

* h.sajerov@gmail.com

Аннотация

Ранняя и точная классификация микрокальцинатов в маммографических изображениях имеет критическое значение для своевременного выявления рака молочной железы. В данной работе представлен новый гибридный фреймворк, сочетающий ResNet-50 с модулем внимания CBAM, Vision Transformer (ViT) и радиомические признаки. Такой дизайн позволяет объединить преимущества глубоких сверточных сетей для извлечения локальных текстурных характеристик, трансформеров для моделирования глобальных зависимостей и радиомики для повышения интерпретируемости и клинической обоснованности. Эксперименты были проведены на датасете CBIS-DDSM с внешней валидацией на INbreast. Результаты продемонстрировали превосходство предложенного подхода над базовыми моделями по всем метрикам: Accuracy = 97,80%, ROC-AUC = 98,4%, при минимальной ошибке калибровки (ECE = 0,023). Важным преимуществом является интеграция Grad-CAM, обеспечивающая прозрачность процесса классификации и позволяющая визуализировать зоны интереса. Таким образом, предложенный гибридный фреймворк представляет собой надёжный и интерпретируемый инструмент, который может способствовать практическому внедрению систем искусственного интеллекта в клиническую маммографию для поддержки принятия решений.

Ключевые слова: рак молочной железы, микрокальцинаты, маммография, глубокое обучение, ResNet-50, CBAM, Vision Transformer, радиомика, объяснимый искусственный интеллект, Grad-CAM

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Для цитирования: Алсаджер Х., Филиппович Ю. Н., Бекетова Т. В. Гибридная архитектура на основе ResNet-50, Vision Transformers и радиомики для интерпретируемой классификации микрокальцинатов в маммографии // Современные информационные технологии и ИТ-образование. 2025. Т. 21, № 3. С. 476-489. <https://doi.org/10.25559/SITITO.021.202503.476-489>

© Алсаджер Х., Филиппович Ю. Н., Бекетова Т. В., 2025



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.



**Research and Development in the Field of New IT
and Their Applications**

A Hybrid Architecture Based on ResNet-50, Vision Transformers, and Radiomics for Interpretable Classification of Microcalcifications in Mammography

H. Alsajer^{a*}, Yu. N. Filippovich^a, T. V. Beketova^b

Original article

^a Moscow Polytechnic University, Moscow, Russian Federation

Address: 38 Bolshaya Semyonovskaya St., Moscow 107023, Russian Federation

^b Central Clinical Hospital of the General Management Department of the President of Russian Federation, Moscow, Russian Federation

Address: 15 Marshal Timoshenko St., Moscow 121359, Russian Federation

*h.sajerov@gmail.com

Abstract

Early and accurate classification of breast microcalcifications in mammographic images is critical for timely breast cancer detection. In this study, we propose a novel hybrid framework that integrates ResNet-50 with the Convolutional Block Attention Module (CBAM), Vision Transformer (ViT), and handcrafted radiomic features. This design combines the strengths of convolutional neural networks for capturing local texture patterns, transformers for modeling global dependencies, and radiomics for improving interpretability and clinical reliability. Experiments were conducted on the CBIS-DDSM dataset with external validation on INbreast. The results demonstrated that the proposed approach outperformed baseline models across all metrics: Accuracy = 97.80%, ROC-AUC = 98.4%, while achieving a minimal calibration error (ECE = 0.023). An additional advantage is the integration of Grad-CAM, which enhances explainability by visualizing the regions of interest that drive the classification decision. Overall, the proposed hybrid framework provides a robust and interpretable tool that holds strong potential for clinical translation in mammographic computer-aided diagnosis systems.

Keywords:

breast cancer, microcalcifications, mammography, deep learning, ResNet-50, CBAM, Vision Transformer, radiomics, explainable AI, Grad-CAM

Conflict of interests:

The authors declares no conflict of interest.

For citation:

Alsajer H., Filippovich Yu.N., Beketova T.V. A Hybrid Architecture Based on ResNet-50, Vision Transformers, and Radiomics for Interpretable Classification of Microcalcifications in Mammography. *Modern Information Technologies and IT-Education*. 2025;21(3):476-489. <https://doi.org/10.25559/SITITO.021.202503.476-489>




Введение

Рак молочной железы (РМЖ) относится к числу наиболее значимых онкологических заболеваний, возникающих в результате неконтролируемого пролиферативного роста клеток в ткани молочной железы. Чаще всего патологический процесс приводит к формированию опухоли, которая может быть выявлена методами визуализации, включая маммографию [2].

В России РМЖ представляет собой серьёзную медико-социальную проблему, характеризующуюся устойчивым ростом заболеваемости и смертности на протяжении последних десятилетий. По данным за 2023 год, РМЖ занимает первое место среди онкологических заболеваний у женщин: около 40% случаев выявляется при профилактических скрининговых обследованиях или случайно в рамках непрофильных консультаций. Это подчёркивает ключевую роль ранней диагностики в повышении выживаемости пациенток [6].

Эпидемиологические данные свидетельствуют о неблагоприятной динамике: стандартизованные по возрасту показатели заболеваемости увеличились с 33,0 на 100 000 населения в 1993 году до 236,47 на 100 000 в 2023 году, что на 5,2% выше по сравнению с предыдущими годами [23], [44]. Несмотря на наблюдаемое снижение смертности, особенно среди

женщин старших возрастных групп, общие показатели летальности остаются высокими – от 54,4 до 61,4 случая на 1000 человеко-лет в период с 2014 по 2019 годы [41]. Такая ситуация указывает одновременно на достижения в области диагностики и лечения, а также на сохраняющиеся системные вызовы в здравоохранении. На глобальном уровне проблема РМЖ имеет ещё больший масштаб: в 2022 году было зарегистрировано около 2,3 миллиона новых случаев и 666 тысяч смертей, что составило 23,8% и 15,4% всех онкологических заболеваний и летальных исходов среди женщин соответственно. Возраст-стандартизованный показатель заболеваемости составил 46,8 на 100 000 населения [42]. Наибольшая нагрузка фиксируется в Восточной Азии (480 019 случаев, ASIR: 37,54/100 000), затем в Северной Америке (306 307 случаев, ASIR: 95,12/100 000) [42]. На уровне отдельных стран лидерами по числу случаев являются Китай (16% всех мировых случаев), США (12%) и Индия (8%) (рис. 1). Кроме того, именно в Южной и Центральной Азии наблюдается наибольшее количество случаев раннего выявления РМЖ (44 266), при этом наибольший вклад дают Китай (13%), Индия (11%) и США (7%) (рис. 1) [42].



Р и с. 1. Доля на уровне страны в предполагаемых случаях заболевания и смерти от рака молочной железы у женщин во всем мире в 2022 году. (А, В) Доля от общего числа случаев (А) и случаев раннего начала (В) рака молочной железы. (С, D) Доля от общего числа случаев (С) и случаев раннего начала (D) рака молочной железы.

F i g. 1. Country-level share of the estimated global burden of female breast cancer incidence and mortality in 2022. (A, B) Proportion of total breast cancer cases (A) and early-onset breast cancer cases (B). (C, D) Proportion of total breast cancer deaths (C) and early-onset breast cancer deaths (D).

Источники: здесь и далее в статье все таблицы и рисунки составлены авторами.
Source: Hereinafter in this article all tables and figures were made by the authors.



Т а б л и ц а 1. Заболеваемость раком молочной железы (новые случаи) и смертность (смерти) в 2020 году по регионам мира и уровню индекса человеческого развития [4]
Table 1. Breast cancer incidence (new cases) and mortality (deaths) in 2020 by world region and Human Development Index (HDI) level [4]

Регион	Население (в миллионах)	Новые случаи	Смерти
Northern America	186,3	281,591	48,407
Central America	91,6	38,916	10,429
South America	218,7	156,472	41,681
Northern Europe	53,8	83,177	17,964
Central-Eastern Europe	155,2	158,708	51,488
Southern Europe	78,5	120,185	28,607
Eastern Asia	822,6	551,636	141,421
South-Eastern Asia	334,7	158,939	58,670
South Central Asia	977,1	254,881	124,975
Western Asia	132,6	60,715	20,943
Australia/New Zealand	15,3	23,277	3792
China	705,5	416,371	117,174
India	662,9	178,361	90,408
Eastern Africa	224,4	45,709	24,047
Middle Africa	90,0	17,896	9500
Northern Africa	122,5	57,128	21,524
Southern Africa	34,3	16,526	5090
Western Africa	199,6	49,339	25,626
Melanesia	5,5	2215	1121
World	3864,8	2,261,419	684,996

Своевременное выявление рака молочной железы имеет ключевое значение, однако данный процесс осложняется тем, что на ранних стадиях заболевание часто протекает бессимптомно. Использование диагностических методов, таких как маммография, ультразвуковое исследование и биопсия, играет решающую роль в дифференциации доброкачественных и злокачественных изменений ткани [36].

Несмотря на эффективность традиционной диагностики, она требует значительных временных затрат и высокого уровня квалификации специалистов. Даже опытные патологоанатомы подвержены риску ошибок из-за человеческого фактора и межэкспертной вариабельности. В ответ на эти ограничения начали активно применяться системы компьютерной поддержки принятия решений (САПР), которые продемонстрировали способность значительно повысить точность диагностики и сократить нагрузку на врачей [3]. Современные САПР базируются на алгоритмах искусственного интеллекта (ИИ), что позволяет улучшить интерпретацию маммограмм за счёт автоматического выделения подозрительных областей и предоставления врачам вспомогательных диагностических классификаций [25].

Применяемые в ИИ-системах методы можно условно разделить на две категории: классические алгоритмы машинного обучения, основанные на извлечении заранее определённых признаков, и алгоритмы глубокого обучения, способные самостоятельно выявлять релевантные характеристики из исходных данных [30]. Первые (например, алгоритм К-ближайших соседей или дерева решений) показывают

ограниченную эффективность при работе с большими и многомерными наборами данных, так как требуют сложной ручной инженерии признаков и глубоких предметных знаний [32]. Напротив, глубокие нейронные сети (DNN), включающие многослойные структуры [7], позволяют автоматически выделять информативные признаки, адаптируясь к специфике данных и обеспечивая высокую точность прогнозов. Эта способность к автоматическому извлечению признаков стала определяющим фактором в достижении выдающихся результатов в области диагностики РМЖ с использованием методов визуализации [10].

В настоящем исследовании предлагается гибридная триблочная архитектура для классификации микрокальцинатов в маммографических изображениях. Первая ветвь построена на ResNet-50, дополненной модулем внимания CBAM, что обеспечивает эффективное выделение локальных текстурных и морфологических характеристик с акцентом на наиболее значимых областях изображения. Вторая ветвь реализована на основе Vision Transformer (ViT), способного моделировать дальнедействующие зависимости и формировать глобальное представление пространственной структуры микрокальцинатов. Третья ветвь объединяет радиомические признаки (GLCM), обеспечивающие интерпретируемое и воспроизводимое дополнение к признаковому пространству.

Все три ветви интегрируются на уровне признаков (*feature-level fusion*), формируя комплексное многомерное представление, которое подаётся на классификатор. Такой подход позволяет достичь



оптимального баланса между локальной детализацией, глобальным контекстом и клинической интерпретируемостью. Дополнительно модель оснащена механизмами объяснимого ИИ (XAI), включая Grad-CAM и карты внимания ViT, что обеспечивает визуализацию вклада отдельных признаков в итоговое решение. Это делает архитектуру не только высокоточной, но и прозрачной, что является ключевым условием для её применения в реальной клинической практике.


Микрокальцинаты

Микрокальцинаты представляют собой мелкие отложения кальция в ткани молочной железы, которые чаще всего выявляются при маммографическом исследовании. В ряде случаев они становятся первым, а иногда и единственным признаком наличия опухолевого процесса, в частности протоковой карциномы *in situ* (DCIS) [29]. Само по себе наличие микрокальцинатов рассматривается как независимый фактор риска развития рака молочной железы, особенно при сочетании с высокой плотностью ткани по системе BI-RADS [18].

С морфологической точки зрения различают несколько типов микрокальцинатов: оксалатные (преимущественно ассоциируются с доброкачественными изменениями) и

гидроксиапатитные (могут встречаться как при злокачественных, так и при доброкачественных процессах) [39], [22]. Согласно критериям BI-RADS, форма и характер распределения микрокальцинатов имеют прогностическое значение: так, тонкие ветвящиеся структуры (*fine-linear branching*) чаще ассоциируются с злокачественностью, в то время как плотные округлые отложения считаются менее подозрительными [40]. Клиническая значимость микрокальцинатов заключается не только в ранней диагностике, но и в планировании объёма хирургического вмешательства, а также в прогнозировании исходов лечения [37].

Кальцификаты молочной железы подразделяются на макро- и микрокальцинаты [28]. Макрокальцинаты визуализируются на маммограммах в виде крупных белых пятен, распределённых хаотично, и, как правило, носят доброкачественный характер. В отличие от них, микрокальцинаты выглядят как небольшие яркие точки, нередко сгруппированные в отдельных областях ткани. Их появление рассматривается как один из наиболее ранних индикаторов рака молочной железы или наличия предраковых изменений. На рисунке 2 приведён пример изображения массы и кальцификаций из набора данных INBreast, демонстрирующий характерные особенности этих структур.



Р и с. 2. Иллюстрация массы и кальцификации из набора данных INBreast [12]

Fig. 2. Illustration of a mass lesion and calcifications from the INBreast dataset [12]

Материалы и методы

Описание базы данных

Поднабор изображений молочной железы, подобранный для DDSM (CBIS-DDSM)

В данном исследовании использовались два широко признанных и клинически релевантных открытых набора данных: Curated Breast Imaging Subset of DDSM

(CBIS-DDSM) и INbreast. Их совместное применение позволило не только обучить и протестировать предложенную модель на большом и разнообразном массиве данных, но и провести независимую внешнюю валидацию, что является критически важным для оценки способности алгоритма к обобщению.

CBIS-DDSM представляет собой расширенную версию классического датасета DDSM, включающую декомпрессированные маммографические изображения



с обновлённой разметкой патологических областей и уточнёнными ROI. Аннотация выполнялась квалифицированными маммологами, что гарантирует высокую достоверность данных. Все изображения представлены в формате DICOM. Общий объём CBIS-DDSM составляет 163,6 ГБ и включает 6775 исследований. Коллекция содержит 10 239 изображений, сопровождаемых соответствующими масками и клинико-патологической информацией в формате CSV. Структура набора данных разделена на четыре подмножества: обучающий и тестовый наборы для анализа масс, а также обучающий и тестовый наборы для анализа кальцификаций. В частности, обучающая выборка по массам содержит 1318 изображений опухолевых образований, а тестовая – 378; обучающая выборка по кальцификациям включает 1622 изображения, а тестовая – 326 [20], [14].

INbreast, напротив, отличается компактным объёмом, но высоким качеством изображений и разметки. Он был собран в Португалии и содержит 410 цифровых маммограмм высокого разрешения (FFDM) от 115 пациентов, представленных в формате DICOM. Аннотация выполнена экспертами-рентгенологами и включает массы, кальцификаты, асимметрии и другие находки. Для каждой подозрительной области указаны точные контуры или маркеры, что делает INbreast ценным инструментом как для классификации, так и для задач сегментации [26].

Использование INbreast в качестве независимого тестового набора позволяет проверить способность модели, обученной на CBIS-DDSM, к переносу на внешние данные, что критически важно для оценки её клинической применимости и потенциальной интеграции в практику [26].

Предварительная обработка изображения

Предварительная обработка маммографических изображений является фундаментальным этапом анализа, определяющим качество извлечения признаков и стабильность работы гибридных моделей глубокого обучения. Для обеспечения воспроизводимости и сопоставимости результатов в настоящем исследовании применялись современные подходы, описанные в публикациях Springer и Elsevier.

На первом этапе проводилось улучшение визуализации изображений с использованием локального порогового разделения фона и переднего плана, например, алгоритма Ли. Данный метод эффективно снижает влияние артефактов и уменьшает неоднородность фона, обеспечивая более точное выделение структур тканей. Для повышения контрастности применялась адаптивная гистограммная коррекция с ограничением контраста (CLAHE), которая доказала свою эффективность в задачах маммографии [13]. Одновременно для подавления шумов при сохранении структурной информации использовалась медианная фильтрация [13].

Следующим шагом была нормализация интенсивностей в диапазоне [0, 1] и масштабирование изображений до

фиксированного размера (224×224 пикселя). Эти операции обеспечивают согласованность входных данных, что особенно важно при обучении сверточных и трансформерных моделей глубокого обучения [33].

Для увеличения объема данных и улучшения обобщающих свойств моделей применялась аугментация, включающая вращения, зеркальные отражения, масштабирование и локальные деформации. Такие преобразования позволяют моделям устойчиво распознавать различные варианты визуальных признаков, характерные для аномалий молочной железы, и значительно снижают риск переобучения [43]. На этапе сегментации применялся комбинированный подход, сочетающий традиционные алгоритмы пороговой сегментации с современными сверточными сетями, что обеспечивало точное выделение регионов интереса, включая микрокальцификации и другие патологические структуры. Тщательно настроенный конвейер сегментации позволял сохранять ключевые морфологические особенности тканей при минимизации ложноположительных артефактов [34].


Ранее предложенный конвейер [13], объединяющий алгоритм Ли, CLAHE, нормализацию, медианную фильтрацию, аугментацию и сегментацию, продемонстрировал высокую эффективность на наборах CBIS-DDSM и INbreast. Полученные показатели Dice составляли 85-88 %, а чувствительность – 81-90 %, что подтверждает практическую применимость данного подхода в задачах маммографического анализа [33].

Таким образом, интегрированный подход к предварительной обработке и подготовке данных обеспечивает надежное, воспроизводимое и масштабируемое представление изображений, создавая прочную основу для последующего обучения гибридных моделей глубокого обучения и повышения точности классификации патологий молочной железы.

Гибридная модель

Автоматическая классификация микрокальцинатов на маммографических изображениях остаётся одной из наиболее сложных задач медицинской визуализации. Эти структуры характеризуются малыми размерами, высокой вариативностью морфологии и низким контрастом, что затрудняет их достоверное выявление даже для опытных специалистов и делает алгоритмы чувствительными к шумам и артефактам [9].

Сверточные нейронные сети (CNN), такие как ResNet-50, демонстрируют высокую эффективность в выделении локальных текстурных признаков и обеспечивают высокую точность при тонкой настройке на наборе CBIS-DDSM. Расширение архитектуры за счёт модулей внимания, например, CBAM (*Convolutional Block Attention Module*), позволяет адаптивно выделять информативные пространственные и каналные признаки, усиливая способность сети фокусироваться на патологически значимых областях [15], [38]. Однако ограниченность локального охвата снижает способность сети учитывать глобальный контекст изображения.



Р и с. 3. Схема архитектуры предобработки маммографических изображений CBIS-DDSM/INbreast
F i g. 3. Architecture of the mammographic image preprocessing pipeline for the CBIS-DDSM/INBreast datasets

В отличие от этого, архитектуры Vision Transformer (ViT) способны моделировать дальнедействующие зависимости и выявлять глобальные закономерности, что особенно важно при анализе сложных структур, хотя их применение требует значительных объёмов данных и сопровождается низкой интерпретируемостью [11].

Радиомика обеспечивает извлечение клинически интерпретируемых признаков, таких как GLCM, LBP, GLRLM и вейвлет-дескрипторы, что повышает прозрачность анализа, однако ограничивает адаптивность модели [1], [19]. Современные гибридные подходы, объединяющие CNN с радиомикой или CNN с ViT, демонстрируют рост точности и устойчивости, однако интеграция всех трёх компонент с механизмами объяснимости остаётся малоизученной. Методы визуализации внимания, например Grad-CAM, дополнительно способствуют клинической верификации решений и повышают доверие к автоматическим предсказаниям [11].

Настоящее исследование направлено на разработку комплексной гибридной архитектуры, объединяющей ResNet-50 с СВМ, глобальное представление ViT и радиомические признаки, с целью повышения точности, устойчивости и интерпретируемости классификации микрокальцинатов на маммографических изображениях.

ResNet-50


ResNet-50 является одной из наиболее популярных архитектур семейства ResNet и включает 48 свёрточных

слоёв, один слой максимального объединения (*MaxPool*) и один слой среднего объединения (*AveragePool*). Основой данной архитектуры являются остаточные блоки, которые позволяют эффективно обучать глубокие сети, минимизируя проблему затухающих градиентов.

Ключевым элементом ResNet-50 являются идентификационные соединения (*skip connections*), которые передают входные данные напрямую к концу каждого остаточного блока. Это позволяет сети сосредоточиться на изучении только тех признаков, которые необходимы для формирования целевых выходных данных, облегчая процесс обучения и повышая точность классификации [35].

Применение ResNet-50 в задачах медицинской визуализации, включая классификацию микрокальцинатов на маммографических изображениях, объясняется её способностью выделять локальные текстурные характеристики и устойчивостью к шумам и артефактам. В рамках гибридных моделей ResNet-50 часто используется в сочетании с механизмами внимания и радиомическими признаками, что позволяет объединить локальную детекцию с глобальным контекстом и клинической интерпретируемостью.

Таким образом, ResNet-50 обеспечивает надёжную основу для построения гибридных архитектур глубокого обучения, способных одновременно решать задачи точной классификации и сохранять интерпретируемость результатов.



Р и с. 4. Архитектура модели ResNet-50
F i g. 4. ResNet-50 architecture



Модуль СВАМ

Модуль свёрточного блока внимания (СВАМ) представляет собой двухэтапный механизм, включающий канальное и пространственное внимание. Канальное внимание позволяет сети фокусироваться на наиболее информативных признаках, используя глобальную информацию с карт признаков, тогда как пространственное внимание обеспечивает концентрацию модели на ключевых областях изображения. Такой последовательный подход критически важен для выделения значимых структур на маммографических изображениях [31].

СВАМ формирует карту внимания по двум независимым измерениям на основе промежуточной карты признаков, после чего итоговая карта умножается на входные признаки для адаптивной оптимизации [21]. В канальном модуле внимания входная карта признаков обрабатывается многослойным перцептроном (MLP), а


затем выходные признаки суммируются поэлементно для формирования окончательной карты канального внимания. Итоговая карта умножается на исходные признаки, подготавливая их для дальнейшей обработки в пространственном модуле внимания. Формально это можно выразить следующим образом [21]:

$$M_c(F) = (MLP(AvgPool(F)) + MLP(MaxPool(F))) \quad (1)$$

Пространственный модуль внимания использует выходную карту канального внимания в качестве входной. Итоговая карта пространственного внимания формируется путём поэлементного умножения выходного признака и входных данных модуля, что обеспечивает адаптивное усиление значимых регионов изображения [21]:

$$M_s(F) = (f^{7 \times 7}([AvgPool*(F); MaxPool(F)])) \quad (2)$$

где обозначает функцию активации, $f^{7 \times 7}$ обозначает свёртку 7×7 . Визуализация внимания к каналу представлена на рис. 5.



Р и с. 5. Канал внимания [21]

F i g. 5. Attention module [21]

Гибридная архитектура для классификации микрокальцинатов

Для точной и интерпретируемой классификации микрокальцинатов на маммографических изображениях в настоящем исследовании предложена комплексная гибридная архитектура, интегрирующая локальные, глобальные и радиомические признаки.

Локальные признаки: Attention-ResNet-50

Для анализа локальных текстурных особенностей использовалась модифицированная ResNet-50 с блоками внимания, такими как СВАМ. Этот подход позволяет модели усиливать информативные участки изображения и подавлять фоновые артефакты, обеспечивая более точное выделение патологически значимых структур [16].

Глобальные признаки: Vision Transformer (ViT)

Для учёта глобального контекста изображения применялся Vision Transformer, способный моделировать дальнедействующие зависимости между патчами изображения. ViT доказали свою эффективность в медицинской визуализации, включая маммографию, и позволяют захватывать пространственные закономерности, недоступные чисто свёрточным сетям [5].

Радиомические признаки

Для повышения интерпретируемости модели извлекались классические радиомические дескрипторы, включая статистические признаки первого порядка и

текстурные характеристики, такие как GLCM. Эти признаки могут быть визуально сопоставлены с патологическими структурами, что дополнительно повышает клиническую ценность и устойчивость модели [24].


Слияние признаков (Feature Fusion)

Признаки из трёх источников – локальные CNN-признаки, глобальные ViT-признаки и радиомические дескрипторы – объединяются в единый вектор, который затем обрабатывается полносвязной сетью с нормализацией и dropout. Такая интеграция позволяет объединить различные представления информации, улучшая точность и стабильность классификации. Подобная стратегия подтверждена эффективностью в современных гибридных архитектурах для онкологических изображений [27], [17].

Объяснимость: Grad-CAM

Для визуализации областей внимания модели использовался Grad-CAM, который наглядно отображает зоны, наиболее влияющие на предсказание. Это повышает доверие клиницистов к модели и позволяет сопоставить автоматические решения с экспертной оценкой радиологов [8].

В совокупности предложенная гибридная архитектура обеспечивает согласованное объединение локального, глобального и радиомического анализа, улучшая точность классификации микрокальцинатов и повышая клиническую интерпретируемость автоматических предсказаний.



Р и с. 6. Схема гибридной модели (ResNet-50 + CBAM + Radiomics + ViT)
F i g. 6. Architecture of the hybrid model (ResNet-50 + CBAM + Radiomics + ViT)

Результаты

Сравнительный анализ моделей

Для оценки эффективности предложенного гибридного фреймворка (Attention-ResNet-50 + ViT + радиомика + Grad-CAM) мы провели многоэтапные эксперименты на двух репрезентативных наборах: CBIS-DDSM (основной, для обучения и валидации) и INbreast (внешний, для проверки генерализуемости модели). Оценка проводилась по метрикам Accuracy, Precision, Recall, F1-score, ROC-AUC, а также по показателям калибровки (*Expected Calibration Error* – ECE), которые считаются критически важными для клинического

применения. Результаты на CBIS-DDSM, на внутренней кросс-валидации гибридная архитектура продемонстрировала превосходство над отдельными компонентами.

Параметры обучения гибридной модели

- Форма изображения (224, 224),
- Начальная скорость обучения: 1×10^{-4} ,
- Размер батча: 16,
- Эпохи: 30 (дальнейшее обучение не давало значительного улучшения),
- Функция потерь: бинарная кросс-энтропия.

Т а б л и ц а 2. Сравнение с базовыми моделями

T a b l e 2. Comparison with baseline models

Модель	Accuracy (%)	Precision (%)	Recall (%)	F1-score (%)	ROC-AUC (%)	ECE
ResNet50 (базовая)	92.6	93.2	92.1	92.3	92.6	0.091
ResNet50 + CBAM	96.8	97.1	96.2	96.6	97.0	0.062
Предложенный гибрид (ResNet-50 + CBAM + Radiomics + ViT)	97.80	98.44	97.60	97.30	98.4	0.023

Как видно, предложенная гибридная архитектура существенно превосходит все базовые конфигурации, обеспечивая наилучшие результаты по всем метрикам


(Табл. 2). Особенно важно, что достигнута минимальная ошибка калибровки ($ECE = 0.023$), что подтверждает надёжность вероятностных предсказаний модели.

Т а б л и ц а 3. Междатасетная генерализация

T a b l e 3. Cross-dataset generalization


Модель	Accuracy (%)	ROC-AUC (%)	ECE
CBIS-DDSM (внутр.)	97.80	98.4	0.023
INbreast (внеш.)	96.70	97.20	0.042

Результаты подтверждают высокую способность модели к обобщению: даже при переходе на другой датасет (INbreast) сохраняется высокая точность и минимальная ошибка калибровки, что критически важно для реальной клинической практики (Табл. 3).




Р и с. 7. Кривые эффективности классификации в наборе данных CBIS-DDSM с использованием Resnet-50

F i g. 7. Classification performance curves on the CBIS-DDSM dataset using ResNet-50




гибридная модель(Resnet-50 + CBAM + Radiomics + ViT)

Р и с. 8. Кривые эффективности классификации в наборе данных CBIS-DDSM с использованием (Resnet-50 + CBAM + Radiomics + ViT)
F i g. 8. Classification performance curves on the CBIS-DDSM dataset using ResNet-50 + CBAM + Radiomics + ViT




Resnet-50 on INbreast dataset

Р и с. 9. Кривые эффективности классификации в наборе данных INbreast с использованием ResNet-50
F i g. 9. Classification performance curves on the INBreast dataset using ResNet-50



Гибридная модель(Resnet-50 + CBAM + Radiomics + ViT) on INbreast dataset

Р и с. 10. Кривые эффективности классификации в наборе данных INbreast (внеш.) с использованием (Resnet-50 + CBAM + Radiomics + ViT)
F i g. 10. Classification performance curves on the external INBreast dataset using ResNet-50 + CBAM + Radiomics + ViT



Р и с. 11. Тепловые карты (Grad-CAM) на CBIS-DDSM/ INbreast: (a, c) исходные изображения, (b, d) тепловые карты. Цвет меняется в зависимости от вероятности прогнозов. Цветовая шкала визуально отображает вероятность наличия микрокальцинатов в данной области; она варьируется от синего до красного, что соответствует 0% и 100% соответственно.

F i g. 11. Grad-CAM heatmaps for the CBIS-DDSM/INbreast datasets: (a, c) original images; (b, d) heatmaps. The color varies according to the predicted probability. The color scale visually represents the probability of the presence of microcalcifications in a given region, ranging from blue to red, corresponding to 0% and 100%, respectively.

Клиническая применимость

Предложенный гибридный подход обладает высокой клинической значимостью. Интеграция локальных признаков (ResNet-50 + CBAM), глобального контекста (ViT) и радиомических дескрипторов обеспечивает как высокую точность, так и интерпретируемость результатов. Это делает модель особенно ценной в задачах ранней диагностики рака молочной железы, где критически важно сочетание чувствительности и клинической прозрачности. Использование Grad-CAM позволяет визуализировать зоны интереса, что способствует доверию со стороны радиологов и облегчает внедрение в рабочие процессы. Дополнительным преимуществом является стабильная генерализация на внешнем датасете INbreast, что подтверждает готовность модели к практической трансляции.

Ограничения

Основным ограничением исследования является использование относительно ограниченного числа публичных датасетов (CBIS-DDSM и INbreast), что не охватывает всего спектра клинических вариаций. Кроме того, радиомические признаки извлекались только из маммографических ROI, что может ограничивать универсальность подхода для других модальностей.

Заключение

В данной работе представлен новый гибридный фреймворк для классификации микрокальцинатов, объединяющий ResNet-50 с модулем внимания CBAM, Vision Transformer и радиомические признаки. Такой дизайн позволил учесть как локальные текстурные особенности, так и глобальные пространственные взаимосвязи, а также добавить интерпретируемые количественные характеристики. Проведённые эксперименты на CBIS-DDSM и внешняя валидация на INbreast показали, что предложенная архитектура превосходит базовые модели по ключевым метрикам (Accuracy = 97.80%, ROC-AUC = 98.4%), при этом достигая минимальной ошибки калибровки (ECE = 0.023). Важно отметить, что высокая интерпретируемость обеспечивается как использованием радиомики, так и методами визуализации внимания (Grad-CAM), что повышает доверие со стороны клиницистов. Полученные результаты подтверждают перспективность предложенного подхода для практического внедрения в системы поддержки принятия решений в маммографии. В будущем работа может быть расширена на более широкие клинические когорты и мультицентровые данные, а также дополнена интеграцией мультимодальной визуализации. Таким образом, гибридный подход открывает путь к более надёжным и объяснимым инструментам раннего выявления рака молочной железы.



References

1. Aerts H.J.W.L., et al. Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach. *Nature communications*. 2014;5:4006. <https://doi.org/10.1038/ncomms5006>
2. Ara S., Das A., Dey A. Malignant and Benign Breast Cancer Classification using Machine Learning Algorithms. In: 2021 International Conference on Artificial Intelligence (ICAI). Islamabad, Pakistan: IEEE Press; 2021. p. 97-101. <https://doi.org/10.1109/ICAI52203.2021.9445249>
3. Araújo T., et al. Classification of breast cancer histology images using Convolutional Neural Networks. *PLoS ONE*. 2017;12(6):e0177544. <https://doi.org/10.1371/journal.pone.0177544>
4. Arnold M., et al. Current and future burden of breast cancer: Global statistics for 2020 and 2040. *The Breast*. 2022;66:15-23. <https://doi.org/10.1016/j.breast.2022.08.010>
5. Ayana G., et al. Vision-transformer-based transfer learning for mammogram classification. *Diagnostics*. 2023;13(2):178. <https://doi.org/10.3390/diagnostics13020178>
6. Barchuk A., Raskina Y., Tursun-Zade R., Craig H., Are C., Gushchin V. Cancer on the Global Stage: Incidence and Cancer-Related Mortality in the Russian Federation. *JAMA. ASCO Post*. 2022.
7. Bejani M.M., Ghatee M.A systematic review on overfitting control in shallow and deep neural networks. *Artificial Intelligence Review*. 2021;54:6391-6438. <https://doi.org/10.1007/s10462-021-09975-1>
8. Camurdan O., et al. Annotation-efficient, patch-based, explainable deep learning using curriculum method for breast cancer detection in screening mammography. *Insights into Imaging*. 2025;16:60. <https://doi.org/10.1186/s13244-025-01922-w>
9. Chan H.P., Samala R.K., Hadjiiski L.M., Zhou C. Deep Learning in Medical Image Analysis. In: Lee, G., Fujita, H. (eds) Deep Learning in Medical Image Analysis. *Advances in Experimental Medicine and Biology*. Vol. 1213. Cham: Springer; 2020. p. 3-21. https://doi.org/10.1007/978-3-030-33128-3_1
10. Cheng J.-Z., et al. Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans. *Scientific reports*. 2016;6:24454. <https://doi.org/10.1038/srep24454>
11. Dosovitskiy A., et al. An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv*:2010.11929. 2020. <https://doi.org/10.48550/arXiv.2010.11929>
12. Du H., Feng J., Feng M. Zoom in to where it matters: a hierarchical graph based model for mammogram analysis. *arXiv*:1912.07517. 2019. <https://doi.org/10.48550/arXiv.1912.07517>
13. El-Banby G.M., et al. Automated abnormalities detection in mammography using deep learning. *Complex and Intelligent Systems*. 2024;10:7279-7295. <https://doi.org/10.1007/s40747-024-01532-x>
14. Hassan N.M., Hamad S., Mahar K. Mammogram breast cancer CAD systems for mass detection and classification: a review. *Multimedia Tools and Applications*. 2022;81:20043-20075. <https://doi.org/10.1007/s11042-022-12332-1>
15. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE Press; 2016. p. 770-778. <https://doi.org/10.1109/CVPR.2016.90>
16. Islam W., et al. Improving performance of breast lesion classification using a ResNet50 model optimized with a novel attention mechanism. *Tomography*. 2022;8(5):2411-2425. <https://doi.org/10.3390/tomography8050200>
17. Zhenfei W., et al. Hybrid Feature Extraction for Breast Cancer Classification Using the Ensemble Residual VGG16 Deep Learning Model. *Current Bioinformatics*. 2025;20:149-163. <https://doi.org/10.2174/011574893633380240816053223>
18. Kim S., et al. Microcalcifications, mammographic breast density, and risk of breast cancer: a cohort study. *Breast Cancer Research*. 2022;24:96. <https://doi.org/10.1186/s13058-022-01594-0>
19. Kumar V., et al. Radiomics: the process and the challenges. *Magnetic Resonance Imaging*. 2012;30(9):1234-1248. <https://doi.org/10.1016/j.mri.2012.06.010>
20. Lee R.S., et al. A curated mammography data set for use in computer-aided detection and diagnosis research. *Scientific data*. 2017;4:170177. <https://doi.org/10.1038/sdata.2017.177>
21. Li R., et al. Breast cancer X-ray image staging: based on efficient net with multi-scale fusion and cbam attention. *Journal of Physics: Conference Series*. 2021;2082 (2021):012006. <https://doi.org/10.1088/1742-6596/2082/1/012006>
22. Logullo A.F., et al. Breast microcalcifications: Past, present and future. *Molecular and clinical oncology*. 2022;16(4):81. <https://doi.org/10.3892/mco.2022.2514>
23. Mahanani M.R., et al. Comparison of female breast cancer between Russia and Germany: A population-based study on time trends and stage at diagnosis. *Cancer Epidemiology*. 2022;80:102214. <https://doi.org/10.1016/j.canep.2022.102214>
24. Mahmood T., et al. An Automatic Detection and Localization of Mammographic Microcalcifications ROI with Multi-Scale Features Using the Radiomics Analysis Approach. *Cancers*. 2021;13(23):5916. <https://doi.org/10.3390/cancers13235916>
25. Moghbel M., Mashohor S. A review of computer assisted detection/diagnosis (CAD) in breast thermography for breast cancer detection. *Artificial Intelligence Review*. 2013;39:305-313. <https://doi.org/10.1007/s10462-011-9274-2>



26. Moreira I.C., et al. Inbreast: toward a full-field digital mammographic database. *Academic radiology*. 2012;19(2):236-248. <https://doi.org/10.1016/j.acra.2011.09.014>
27. Murty P.S.R.C., et al. Integrative hybrid deep learning for enhanced breast cancer diagnosis: leveraging the Wisconsin Breast Cancer Database and the CBIS-DDSM dataset. *Scientific Reports*. 2024;14:26287. <https://doi.org/10.1038/s41598-024-74305-8>
28. Nalawade Y.V. Evaluation of breast calcifications. *Indian Journal of radiology and imaging*. 2009;19(4):282-286. <https://doi.org/10.4103/0971-3026.57208>
29. O'Grady S., Morgan M.P. Microcalcifications in breast cancer: From pathophysiology to diagnosis and prognosis. *Biochimica et Biophysica Acta – Reviews on Cancer*. 2018;1869(2):310-320. <https://doi.org/10.1016/j.bbcan.2018.04.006>
30. Sajid U., et al. Breast cancer classification using deep learned features boosted with handcrafted features. *Biomedical Signal Processing and Control*. 2023;86(C):105353. <https://doi.org/10.1016/j.bspc.2023.105353>
31. Sengodan N. EfficientNet with Hybrid Attention Mechanisms for Enhanced Breast Histopathology Classification : A Comprehensive Approach. *arXiv:2410.22392v2*. 2024.
32. Shah S.M., et al. Artificial intelligence for breast cancer analysis: Trends & directions. *Computers in Biology and Medicine*. 2022;142:105221. <https://doi.org/10.1016/j.combiomed.2022.105221>
33. Sharma S., Singh Y., Choudhury T. Advanced deep learning architectures for enhanced mammography classification : a comparative study of CNNs and ViT. *Discover Artificial Intelligence*. 2025;5:187. <https://doi.org/10.1007/s44163-025-00426-2>
34. Singh L., Alam A. An efficient hybrid methodology for an early detection of breast cancer in digital mammograms. *Journal of Ambient Intelligence and Humanized Computing*. 2024;15:337-360. <https://doi.org/10.1007/s12652-022-03895-w>
35. Teoh J.R., et al. Enhancing early breast cancer diagnosis through automated microcalcification detection using an optimized ensemble deep learning framework. *PeerJ Computer Science*. 2024;10:e2082. <https://doi.org/10.7717/peerj-cs.2082>
36. Le Thi H.A., Nguyen V.V., Ouchani S. Gene Selection for Cancer Classification Using DCA. In: Tang C., Ling C.X., Zhou X., Cercone N.J., Li X. (eds.) Advanced Data Mining and Applications. ADMA 2008. *Lecture Notes in Computer Science*. Vol. 5139. Berlin, Heidelberg: Springer; 2008. p. 62-72. https://doi.org/10.1007/978-3-540-88192-6_8
37. Tot T., et al. The clinical value of detecting microcalcifications on a mammogram. *Seminars in Cancer Biology*. 2021;72:165-174. <https://doi.org/10.1016/j.semcancer.2019.10.024>
38. Woo S., et al. CBAM: Convolutional Block Attention Module. In: Computer Vision – ECCV 2018: 15th European Conference, Munich, Germany, September 8–14, 2018, Proceedings, Part VII. *Lecture Notes in Computer Science*. Vol. 11211. Cham: Springer; 2018. p. 3-19. https://doi.org/10.1007/978-3-030-01234-2_1
39. Yang Y., et al. Microcalcification-based tumor malignancy evaluation in fresh breast biopsies with hyperspectral stimulated Raman scattering. *Analytical Chemistry*. 2021;93(15):6223-6231. <https://doi.org/10.1021/acs.analchem.1c00522>
40. Yu L., et al. Detection and diagnosis of automated breast ultrasound in patients with BI-RADS category 4 microcalcifications : a retrospective study. *BMC Medical Imaging*. 2024;24:126. <https://doi.org/10.1186/s12880-024-01287-4>
41. Zakharova N.A., Duffy S.W., Mackay J., Kotlyarov E.V. The introduction of a breast cancer screening programme in a region with a population at medium-risk for breast cancer: Khanty-Mansiysky autonomous Okrug-Ugra (Russian Federation). *Ecancer*. 2011;5:195. <https://doi.org/10.3332/ecancer.2011.195>
42. Zhang Y., et al. Journal of the National Cancer Center Global burden of female breast cancer: new estimates in 2022, temporal trend and future projections up to 2050 based on the latest release from GLOBOCAN 2025. *Journal of the National Cancer Center*. 2025;5(3):287-296. <https://doi.org/10.1016/j.jncc.2025.02.002>
43. Zheng T., et al. Deep learning-enabled fully automated pipeline system for segmentation and classification of single-mass breast lesions using contrast-enhanced mammography: a prospective, multicentre study. *EClinicalMedicine*. 2023;58:101913. <https://doi.org/10.1016/j.eclinm.2023.101913>
44. Shakhzadova A.O., Starinsky V.V., Lisichnikova I.V. Cancer care to the population of Russia in 2022. *Siberian journal of oncology*. 2023;22(5):5-13. (In Russ., abstract in Eng.) <https://doi.org/10.21294/1814-4861-2023-22-5-5-13>

Поступила 14.06.2025; одобрена после
рецензирования 05.08.2025; принята к публикации
04.09.2025.

Submitted 14.06.2025; approved after reviewing
05.08.2025; accepted for publication 04.09.2025.



Об авторах:

Алсаджер Хуссейн, аспирант, ФГАОУ ВО «Московский политехнический университет» (107023, Российская Федерация, г. Москва, ул. Большая Семёновская, д. 38), **ORCID:** <https://orcid.org/0009-0003-1862-1059>, h.sajerov@gmail.com

Филиппович Юрий Николаевич, профессор кафедры инфокогнитивных технологий, ФГАОУ ВО «Московский политехнический университет» (107023, Российская Федерация, г. Москва, ул. Большая Семёновская, д. 38), кандидат технических наук, профессор, **ORCID:** <https://orcid.org/0000-0001-9419-2282>, y_philippovich@mail.ru

Бекетова Татьяна Валентиновна, заведующий ревматологическим отделением, ФГБУ «Центральная клиническая больница с поликлиникой» Управления делами Президента Российской Федерации (121359, Российская Федерация, г. Москва, ул. Маршала Тимошенко, д. 15), доктор медицинских наук, **ORCID:** <https://orcid.org/0000-0003-2641-9785>, tvbek@rambler.ru

Все авторы прочитали и одобрили окончательный вариант рукописи.

About the authors:

Hussein Alsajer, Postgraduate Student, Moscow Polytechnic University (38 Bolshaya Semyonovskaya St., Moscow 107023, Russian Federation), **ORCID:** <https://orcid.org/0009-0003-1862-1059>, h.sajerov@gmail.com

Yuri N. Philippovich, Professor of the Department of Infocognitive Technologies, Moscow Polytechnic University (38 Bolshaya Semyonovskaya St., Moscow 107023, Russian Federation), Cand. Sci. (Eng.), Professor, **ORCID:** <https://orcid.org/0000-0001-9419-2282>, y_philippovich@mail.ru

Tatyana V. Beketova, Head of the Rheumatology Department, Central Clinical Hospital of the General Management Department of the President of Russian Federation (15 Marshal Timoshenko St., Moscow 121359, Russian Federation), Dr. Sci. (Med.), **ORCID:** <https://orcid.org/0000-0003-2641-9785>, tvbek@rambler.ru

All authors have read and approved the final manuscript.