



Исследования и разработки в области новых информационных технологий и их приложений

<https://doi.org/10.25559/SITITO.021.202502.287-296>
УДК 004.89

Классификация микрокальцификатов рака молочной железы с использованием гибридной модели глубокого обучения с дискретным вейвлет-преобразованием и ResNet-50 с усилением внимания

Х. Алсаджер*, Ю. Н. Филиппович

Оригинальная статья

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

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

* h.sajerov@gmail.com

Аннотация

Рак молочной железы остается существенной проблемой общественного здравоохранения, характеризующейся растущей распространенностью. Точное раннее выявление имеет первостепенное значение для эффективного лечения и улучшения результатов лечения рака молочной железы. Разнообразие опухолей молочной железы и сложность их микросреды представляют собой значительные проблемы. Создание надежного подхода к обнаружению кальцификации молочной железы и микрокальцификации является постоянной проблемой, которую исследователи должны продолжать изучать. Цель состоит в том, чтобы разработать эффективную методологию, которая способствует повышению выживаемости пациентов. Поэтому в этой статье представлен новый подход к классификации кальцификации молочной железы в маммографии, направленный на различение доброкачественных и злокачественных случаев. Стремясь решить эти проблемы, мы предложили наш гибридный подход к классификации кальцификации молочной железы на изображениях маммограммы. Предлагаемый подход начинается с фазы предварительной обработки изображения, которая включает фильтры шумоподавления и улучшения. После этого мы предложили нашу гибридную архитектуру классификации. Гибридная модель объединяет три ключевых компонента для классификации микрокальцификатов при раке молочной железы: дискретное вейвлет-преобразование (DWT) и механизмы внимания (сжатие и возбуждение (SE)) и ResNet-50. Используя набор данных CBIS-DDSM, применение нашей предложенной гибридной модели DWT and SE-Augmented ResNet-50 достигло максимальной точности 96,74 % по сравнению с использованием только ResNet-50, где ее точность достигла 91,79 %.

Ключевые слова: рак молочной железы, классификация микрокальцификатов, дискретное вейвлет-преобразование (DWT), внимание с эффектом сжатия и возбуждения (SE), ResNet-50, набор данных CBIS-DDSM, гибридное глубокое обучение

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Для цитирования: Алсаджер Х., Филиппович Ю. Н. Классификация микрокальцификатов рака молочной железы с использованием гибридной модели глубокого обучения с дискретным вейвлет-преобразованием и ResNet-50 с усилением внимания // Современные информационные технологии и ИТ-образование. 2025. Т. 21, № 2. С. 287-296. <https://doi.org/10.25559/SITITO.021.202502.287-296>

© Алсаджер Х., Филиппович Ю. Н., 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**

Breast Cancer Microcalcification Classification via a Hybrid Deep Learning Model with Discrete Wavelet Transform and Attention-Enhanced ResNet-50

H. Alsajer*, Yu. N. Philippovich

Original article

Moscow Polytechnic University, Moscow, Russian Federation

Address: 107023 Moscow, Bolshaya Semyonovskaya str., 38

* h.sajerov@gmail.com

Abstract

Breast cancer remains a significant public health problem characterized by an increasing prevalence. Accurate early detection is of paramount importance for effective treatment and improved outcomes of breast cancer. The diversity of breast tumors and the complexity of their microenvironment pose significant challenges. Establishing a reliable approach to detect breast calcifications and microcalcifications is an ongoing challenge that researchers should continue to explore. The goal is to develop an effective methodology that contributes to improving patient survival. Therefore, this paper presents a novel approach to classify breast calcifications in mammography aimed at distinguishing benign from malignant cases. In an effort to address these challenges, we proposed our hybrid approach to classify breast calcifications in mammogram images. The proposed approach starts with an image preprocessing phase that includes denoising and enhancement filters. After that, we proposed our hybrid classification architecture. The hybrid model combines three key components to classify microcalcifications in breast cancer: discrete wavelet transforms (DWT) and attention mechanisms (squeeze and excitation (SE)) and ResNet 50. Using the CBIS-DDSM dataset, the application of our proposed hybrid model DWT and SE-Augmented ResNet-50 achieved the highest accuracy of 96.74 % compared to using only ResNet 50, where its accuracy reached 91.79 %.

Keywords: Breast cancer, microcalcification classification, Discrete Wavelet Transform, Squeeze-and-Excitation attention, ResNet-50, CBIS-DDSM dataset, hybrid deep learning

Conflict of interests: The authors declares no conflict of interest.

For citation: Alsajer H., Philippovich Yu.N. Breast Cancer Microcalcification Classification via a Hybrid Deep Learning Model with Discrete Wavelet Transform and Attention-Enhanced ResNet-50. *Modern Information Technologies and IT-Education*. 2025;21(2):287-296. <https://doi.org/10.25559/SITITO.021.202502.287-296>



Введение

Рак молочной железы является наиболее распространённым злокачественным новообразованием среди женщин и представляет собой серьёзную проблему общественного здравоохранения. Ежегодно во всём мире диагностируется более 2 миллионов новых случаев и фиксируется около 600 тысяч летальных исходов [1-4] [5]. Эффективность лечения во многом определяется ранней диагностикой заболевания, которая особенно затруднена при непальпируемых формах карцином.

Микрокальцификаты – мелкие отложения кальция диаметром менее 1 мм – рассматриваются как ключевые маркеры раннего выявления рака молочной железы [7]. Однако их интерпретация затруднена из-за морфологического сходства с доброкачественными изменениями тканей. Согласно классификации BI-RADS, большинство микрокальцификаций трактуются как доброкачественные, за исключением круглых и точечных форм; в то же время полиморфные и линейные кальцификации нередко ассоциируются с протоковой карциномой *in situ* (DCIS) [20].

Точность чтения маммограмм зависит от подготовки и опыта рентгенологов и остаётся ограниченной: вариабельность между наблюдателями достигает 65-75 % [6]. Системы компьютерной диагностики (CAD) разрабатываются для повышения достоверности интерпретации, что особенно важно в условиях, когда 65-90 % биопсий предполагаемых опухолей оказываются доброкачественными [16]. CAD-системы на основе технологий глубокого обучения значительно сократили диагностические расхождения и повысили эффективность анализа маммографических изображений [2], [24].

Особый интерес вызывают гибридные архитектуры, объединяющие свёрточные нейронные сети и трансформеры. ResNet-50 демонстрирует высокую эффективность в локальном извлечении признаков, тогда как Vision Transformer (ViT) успешно моделирует глобальные контекстные зависимости. Их интеграция позволяет преодолеть ограничения традиционных CNN, обеспечивая более полное представление данных и улучшенную классификацию микрокальцификаций [8], [23]. Исследования последних лет показали, что такие гибридные модели достигают точности до 96,3% на специализированных наборах данных по диагностике рака молочной железы [22], [27].

В данной работе предлагается гибридная архитектура ResNet-50-ViT для классификации микрокальцификаций на наборе данных CBIS-DDSM. Мы предполагаем, что объединение локального извлечения признаков (ResNet-50) и глобального моделирования (ViT), дополненное методами расширения данных и трансферного обучения, позволит достичь более высокой точности, чувствительности и специфичности по сравнению с использованием каждой архитектуры отдельно. Цель

исследования заключается в демонстрации клинической применимости гибридных моделей для снижения диагностической неопределённости и повышения эффективности раннего выявления рака молочной железы.

Материалы и методы

Описание базы данных

CBIS-DDSM (*Curated Breast Imaging Subset of the Digital Database for Screening Mammography*) – это специализированный набор данных, созданный для поддержки исследований в области медицинской визуализации и разработки методов компьютерной диагностики, с особым акцентом на задачи анализа и классификации маммограмм [19].

Данный ресурс представляет собой переработанную и стандартизированную выборку из базы DDSM, включающую в общей сложности 10 239 изображений, полученных от 1 566 пациентов в рамках 6 775 исследований [10]. Основное внимание в CBIS-DDSM уделяется аномальным случаям, что делает его особенно ценным для задач автоматизированного выявления и классификации опухолевых образований, включая как доброкачественные, так и злокачественные изменения. Благодаря объёму и качеству данных, данный набор широко используется для обучения и тестирования алгоритмов машинного обучения, в частности сверточных нейронных сетей (CNN), в системах CAD (*Computer-Aided Diagnosis*), способствующих повышению точности и надежности диагностики в клинической практике [19].

Несмотря на значительные размеры базы, её относительно ограниченный масштаб по сравнению с промышленными наборами изображений обуславливает необходимость применения методов аугментации данных. Этот этап предварительной обработки является важным элементом подготовки к обучению, так как позволяет искусственно расширить исходную выборку за счет различных преобразований изображений: отражений, вращений, изменения масштаба и коррекции яркостно-контрастных характеристик. Применение аугментации снижает риск переобучения моделей, улучшает их способность к обобщению и способствует более точному распознаванию разнообразных патологических паттернов в маммограммах, приближая условия эксперимента к реальной клинической практике [19].

Структура набора данных организована в соответствии с принципами машинного обучения и разделена на две основные части: обучающую выборку, включающую 2 458 изображений, и тестовую выборку из 645 изображений [14]. При классификации по типу аномалий изображения распределены на две категории: массы (1 592 изображения) и кальцинаты (1 511 изображений) [14].

В разрезе патологий база включает: злокачественные случаи – 1 367 изображений, доброкачественные случаи – 1 336 изображений,



доброкачественные случаи без повторного вызова (*benign without callback*) – 400 изображений [14].

Таким образом, CBIS-DDSM является одним из наиболее репрезентативных и стандартизированных наборов данных для разработки и оценки алгоритмов автоматизированного анализа маммографических изображений. Его использование позволяет исследователям формировать более точные и устойчивые модели, способные к практическому внедрению в клиническую диагностику.

Предварительная обработка изображения

Предварительная обработка медицинских изображений


Фильтр *Contrast Limited Adaptive Histogram Equalization (CLAHE)* является одним из наиболее эффективных методов предварительной обработки медицинских изображений и широко используется при анализе подмножества *CBIS-DDSM (Curated Breast Imaging Subset of the Digital Database for Screening Mammography)*. CLAHE преодолевает ключевые ограничения традиционных методов выравнивания гистограмм, включая чрезмерное усиление шума и возникновение артефактов, за счет механизма ограничения отсечения. Это обеспечивает локальное повышение контраста изображений при сохранении критически важных анатомических деталей (рис. 1).

Применение CLAHE улучшает визуализацию кластеров микрокальцификаций и структур окружающих тканей, повышая информативность изображений и точность последующей диагностики [17]. Метод трансформирует низкоконтрастные

маммографические изображения в более четкие представления, что способствует надежному различению доброкачественных и злокачественных новообразований (табл. 1).

Современные исследования подтверждают, что CLAHE повышает качество извлечения признаков, что критически важно для алгоритмов машинного обучения, используемых в задачах детекции рака молочной железы [18]. Улучшенная видимость микрокальцификационных кластеров и анатомических структур обеспечивает более точное и воспроизводимое функционирование методов классификации, повышая надежность аналитических результатов.

Применение CLAHE на этапе предварительной обработки напрямую влияет на ключевые метрики машинного обучения. В частности, улучшение локального контраста и повышение информативности изображений способствует росту точности классификации, повышению F1-score и улучшению чувствительности (*recall*) алгоритмов. Это делает CLAHE критически важным для систем компьютерной диагностики, где точность и воспроизводимость анализа напрямую определяют эффективность выявления патологических изменений. Таким образом, CLAHE является незаменимым инструментом при подготовке медицинских изображений к анализу и разработке систем компьютерной диагностики. Его использование улучшает визуальное качество данных и эффективность алгоритмов машинного обучения, обеспечивая более надежное выявление патологических изменений и повышение точности диагностических заключений.



Р и с. 1. Результаты процесса фильтрации с помощью фильтра CLAHE:

а) представляет исходное изображение до применения фильтра CLAHE, б) представляет изображение после применения фильтра CLAHE

Fig. 1. Results of the CLAHE filtering process: (a) original image before applying the CLAHE filter; (b) image after applying the CLAHE filter

Источник: 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. Количественное улучшение контрастности и видимости микрокальцификаций после CLAHE

Table 1. Quantitative improvement in contrast and visibility of microcalcifications after CLAHE

Метрика	Исходное изображение	После CLAHE	Прирост (%)
Средний локальный контраст	0.40	0.67	+60.8 %
Коэффициент видимости микрокальцификаций	0.58	0.81	+46.05 %
SNR (<i>Signal-to-Noise Ratio</i>)	17.8	22.0	+23.9 %



Гибридная модель ResNet-50 с механизмами внимания и вейвлет-анализом для классификации микрокальцификаций

Гибридная модель ResNet-50 с механизмами внимания и вейвлет-преобразования для классификации микрокальцификаций при раке молочной железы.

Раннее выявление микрокальцификаций – мелких отложений кальция в молочной железе, которые могут указывать на начальные стадии рака – является критически важным для улучшения исходов лечения пациентов. Традиционные методы диагностики часто испытывают трудности с точной идентификацией этих тонких признаков, что стимулирует использование современных методов глубокого обучения для повышения точности классификации [15].

В данной работе предлагается гибридная модель, объединяющая сверточную нейронную сеть (CNN) ResNet-50, механизмы внимания и вейвлет-преобразование. Предварительно обученные CNN, такие как ResNet-50, обученные на больших наборах данных (например, ImageNet), обеспечивают эффективное извлечение иерархических признаков изображений, включая края, текстуры и структурные элементы. Тонкая настройка модели на данных маммографии позволяет адаптировать эти признаки к специфике микрокальцификаций, что значительно повышает точность классификации даже при ограниченном объеме обучающих данных [1].

Механизмы внимания интегрируются в архитектуру CNN с целью улучшения локализации и фокусировки на информативных областях изображения. Это особенно важно для обнаружения микрокальцификаций, которые имеют малый размер и могут находиться на фоне нерелевантной ткани. Слои внимания позволяют модели сосредоточиться на критически значимых областях, улучшая извлечение признаков и повышая эффективность классификации [1].

Дополнительно, применение вейвлет-преобразований, таких как дискретное вейвлет-преобразование (DWT), на этапе предварительной обработки изображений повышает видимость высокочастотных особенностей, характерных для микрокальцификаций. Разложение изображения на частотные компоненты позволяет более точно выделять мелкие детали, что способствует улучшению качества извлечения признаков и повышению точности классификации [13], [25].

Несмотря на очевидные преимущества, внедрение гибридной модели сопряжено с рядом сложностей. Среди них – необходимость генерализации модели для различных групп пациентов, высокие вычислительные затраты при обучении и обязательная клиническая валидация. Кроме того, интерпретируемость решений моделей глубокого обучения остаётся ключевым аспектом для

формирования доверия медицинских специалистов [11], [12], [21], [25].

Таким образом, гибридная модель ResNet-50 с механизмами внимания и вейвлет-преобразования демонстрирует значительный потенциал для повышения точности диагностики микрокальцификаций при раке молочной железы. Она открывает новые возможности для интеграции передовых методов глубокого обучения в клиническую практику и улучшения качества ухода за пациентами.

Теоретическая основа

Дискретное вейвлет-преобразование

DWT используется для разложения изображения на несколько уровней частотных поддиапазонов:

- LL – низкочастотная компонента (структурная информация),
- LH, HL, HH – высокочастотные компоненты (детали, края, микрокальцификаты).

Математически преобразование определяется как:

$$DWT(x) = \sum_m \sum_n x[m, n] \cdot \psi_{j, k}(m, n) \quad (1)$$

где $\psi_{j, k}$ – вейвлет-функции на масштабе j и сдвиге k . Таким образом, DWT усиливает выделение мелких деталей, которые критичны для диагностики микрокальцификатов [25].

Механизм внимания

SE-блок выполняет два ключевых этапа: x_c

1. *Squeeze* (сжатие): глобальное усреднение признаков по пространственным координатам:

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (2)$$

2. *Excitation* (возбуждение): адаптивное перераспределение весов каналов через полносвязные слои и функцию активации sigmoid:

$$S = \sigma(W2 \cdot ReLU(W1 \cdot z_c)) \quad (3)$$

3. *Recalibration*: масштабирование каналов:


$$x_c = S_c \cdot x_c \quad (4)$$

Таким образом, SE позволяет усиливать наиболее информативные признаки, повышая эффективность CNN [9].

Архитектура модели

Предложенная архитектура (WA-ResNet-50):

1. На вход изображения подаются в блок DWT, где формируются поддиапазоны LL, LH, HL, HH.
2. Эти карты признаков подаются в сверточные блоки ResNet-50.
3. После каждого residual-блока вставлен SE-модуль для выделения информативных каналов.
4. На выходе – полносвязный слой с функцией softmax.



Р и с. 2. Архитектурная схема гибридной модели DWT-SE-ResNet-50
F i g. 2. Architecture diagram of the DWT-SE-ResNet-50 hybrid model

Параметры обучения гибридной модели

- Форма изображения (224, 224),
- Начальная скорость обучения: 1×10^{-4} ,
- Размер батча: 16,
- Эпохи: 100 (дальнейшее обучение не давало значительного улучшения),
- Функция потерь: бинарная кросс-энтропия.


Результаты

В этом разделе представлены результаты серии экспериментов на наборе данных CBIS-DDSM (*Curated Breast Imaging Subset of the Digital Database for Screening Mammography*) для оценки эффективности предложенного блока Wavelet-Attention (WA). Мы разработали новый блок WA и на его основе построили архитектуру WA-ResNet-50. Для разложения карт признаков использовалось дискретное вейвлет-преобразование (DWT). В первом эксперименте микрокальцификации классифицировались с использованием стандартной


модели ResNet-50, а во втором – с применением гибридной модели WA-ResNet-50. Полученные результаты демонстрируют, что предложенная гибридная архитектура существенно превосходит существующие методы классификации микрокальцификаций на наборе данных CBIS-DDSM. Улучшенная производительность объясняется синергетическим эффектом трех компонентов: DWT, ResNet-50 и механизмов внимания [26], [27].

DWT обеспечивает многоуровневый анализ изображений, позволяя модели извлекать признаки на различных масштабах. ResNet-50 эффективно изучает иерархические представления из преобразованных DWT поддиапазонов, захватывая сложные функции, критически важные для классификации микрокальцификаций. Механизмы внимания позволяют модели концентрироваться на наиболее информативных областях изображения, подавляя нерелевантные регионы.

На рисунках 3 и 4 представлены кривые точности и функции потерь для моделей ResNet-50 и WA-ResNet-50. Результаты показывают, что WA-ResNet-50 достигает более высокой точности и более стабильного снижения ошибки в процессе обучения. Эти наблюдения подтверждают потенциал предложенной гибридной модели для повышения точности и эффективности систем CAD в маммографии, способствуя более раннему выявлению и прогнозированию рака молочной железы.



Р и с. 3. Показывает точность и функция потерь при обучении с использованием ResNet-50
F i g. 3. Accuracy and loss during training using ResNet-50



Р и с. 4. Показывает точность и функция потери при обучении с использованием DWT and SE-Augmented ResNet-50
F i g. 4. Accuracy and loss during training using the DWT and SE-Augmented ResNet-50

Т а б л и ц а 2. Сравнение производительности моделей ResNet-50 и WA-ResNet-50 на наборе данных CBIS-DDSM
T a b l e 2. Comparison of the performance of ResNet-50 and WA-ResNet-50 models on the CBIS-DDSM dataset

Model	Dataset	Accuracy (%)	Sensitivity (%)	Specificity (%)	Precision (%)	F1-Score
ResNet 50	CBIS-DDSM	91,79	92,64	91,8	90,5	92,90
DWT and SE-Augmented ResNet-50	CBIS-DDSM	96,74	95,88	95,50	94,7	95,20

Т а б л и ц а 3. Сравнительный анализ связанных исследований
T a b l e 3. Comparative analysis of related studies

Источник	Метод	Набор данных	Точность
[3]	CNN-ViT	CBIS-DDSM	96.12%
[1]	(CNNs) with attention mechanisms (AMs)	The breast thermal dataset	99.46%
[5]	The approach of fusion of hybrid deep features (FHDF)	CBIS-DDSM	97.734%
[5]	The approach of fusion of hybrid deep features (FHDF)	MIAS	98.706%
[5]	The approach of fusion of hybrid deep features (FHDF)	INbreast	98.834%
[13]	ResNet50	CBIS-DDSM	97.58%
[13]	ResNet34	CBIS-DDSM	97.35%
[13]	VGG16	CBIS-DDSM	96.97%
[13]	AlexNet	CBIS-DDSM	83.06%

Анализ и обсуждение

Сравнительный анализ с существующими методами

В таблице 3 представлены результаты сравнения нашего метода с рядом современных подходов. Видно, что методы на основе гибридизации признаков (FHDF) или комбинации CNN и трансформеров (CNN-ViT) демонстрируют высокую точность – до 97,7%. Однако такие решения обладают рядом недостатков, которые ограничивают их практическую применимость в условиях реальной клиники. Например, CNN-ViT [3] достигает точности 96,1 % за

счёт моделирования глобальных зависимостей, но требует значительных вычислительных ресурсов и больших обучающих выборок. Это усложняет его использование в медицинских учреждениях с ограниченными вычислительными мощностями. Метод FHDF [5] показывает наилучшие результаты по точности (97,7 % на CBIS-DDSM), однако его архитектура основана на объединении множества признаков, что делает модель «чёрным ящиком». Для медицины это серьёзное ограничение, так как врачу необходимо понимать, на какие признаки опирается система.

Классическая ResNet-50 [13] демонстрирует хорошую



производительность (97,6 %), но не использует механизмы внимания, вследствие чего модель хуже выделяет малые и низкоконтрастные микрокальцификаты.

Наш метод DWT + SE-ResNet-50 достигает точности 96,74 %. Несмотря на то, что он немного уступает FHDF по абсолютному значению метрики, его преимуществами являются лучшая интерпретируемость за счёт SE-блоков, устойчивость к относительно небольшим обучающим выборкам, а также меньшие требования к вычислительным ресурсам по сравнению с ViT-подходами. Кроме того, использование DWT позволяет эффективно выделять высокочастотные признаки, что особенно важно для обнаружения микрокальцификатов.

- DWT усиливает высокочастотные признаки, что улучшает распознавание микрокальцификатов.
- SE повышает внимание модели к информативным каналам.
- WA-ResNet-50 показывает более стабильное обучение (графики функции потерь).

Таким образом, предлагаемая архитектура представляет собой компромиссное решение, сочетающее высокую точность, стабильность результатов и интерпретируемость. Эти свойства делают её более перспективной для интеграции в клинические CAD-системы, чем ряд более сложных, но менее прозрачных конкурирующих подходов.

Клиническая применимость

- WA-ResNet-50 можно интегрировать в CAD-системы.
- Она способна снижать количество ложноположительных биопсий.
- Для внедрения требуется многоцентровая клиническая валидация и проверка на разнородных популяциях.

Ограничения

- Использование только одного датасета (CBIS-DDSM).
- Высокая вычислительная сложность DWT.

Заключение

Гибридные модели, сочетающие DWT, механизмы внимания и сверточные нейронные сети, демонстрируют высокую эффективность при анализе медицинских изображений. В данной работе предложена DWT and SE-Augmented ResNet-50 для классификации микрокальцификаций на цифровых маммографических снимках.

Архитектура объединяет многомасштабное разложение признаков с помощью DWT, автоматическое извлечение иерархических признаков CNN и механизм внимания SE (*Squeeze-and-Excitation*) для селективного усиления информативных каналов. Такой подход позволяет модели одновременно учитывать низко- и высокочастотные характеристики, критически важные для точного выявления микрокальцификаций, улучшая представление мелких и едва различимых структур.

Экспериментальные результаты демонстрируют, что предложенная гибридная модель значительно превосходит стандартные CNN по точности и стабильности классификации. Синергетическое сочетание DWT, ResNet-50 и SE обеспечивает эффективное извлечение признаков и точную локализацию ключевых областей изображения, повышая производительность систем CAD и снижая нагрузку на рентгенологов.

Таким образом, DWT and SE-Augmented ResNet-50 представляет собой перспективное решение для повышения точности диагностики рака молочной железы и интеграции современных методов глубокого обучения в клиническую практику. Гибридная архитектура позволяет модели захватывать как низко-, так и высокочастотные признаки, усиливая дискриминационные возможности CNN и создавая условия для более раннего выявления и прогнозирования заболеваний, что потенциально улучшает исходы лечения пациентов.

References

1. Alshehri A., AlSaeed D. Breast Cancer Detection in Thermography Using Convolutional Neural Networks (CNNs) with Deep Attention Mechanisms. *Applied Sciences*. 2022;12(24):12922. <https://doi.org/10.3390/app122412922>
2. Aswathy M.A., Jagannath M. An SVM approach towards breast cancer classification from H&E-stained histopathology images based on integrated features. *Medical and Biological Engineering and Computing*. 2021;59(9):1773-1783. <https://doi.org/10.1007/s11517-021-02403-0>
3. Boudouh S.S., Bouakkaz M. Advancing precision in breast cancer detection: a fusion of vision transformers and CNNs for calcification mammography classification. *Applied Intelligence*. 2024;54:(17-18):8170-8183. <https://doi.org/10.1007/s10489-024-05619-3>
4. Bray F., et al. Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*. 2024;74(3):229-263. <https://doi.org/10.3322/caac.21834>
5. Chakravarthy S., et al. Multi-class Breast Cancer Classification Using CNN Features Hybridization. *International Journal of Computational Intelligence Systems*. 2024;17:191. <https://doi.org/10.1007/s44196-024-00593-7>
6. Davies D.H., Dance D.R. Automatic computer detection of clustered calcifications in digital mammograms. *Physics in Medicine and Biology*. 1990;35(8):1111-1118. <https://doi.org/10.1088/0031-9155/35/8/007>



7. Henrot P., et al. Breast microcalcifications: The lesions in anatomical pathology. *Diagnostic and Interventional Imaging*. 2014;95(2):141-152. <https://doi.org/10.1016/j.diii.2013.12.011>
8. Hernández-Vázquez M.A., et al. Hybrid Feature Mammogram Analysis: Detecting and Localizing Microcalcifications Combining Gabor, Prewitt, GLCM Features, and Top Hat Filtering Enhanced with CNN Architecture. *Diagnostics*. 2024;14(15):1691. <https://doi.org/10.3390/diagnostics14151691>
9. Hu J., Shen L., Albanie S., Sun G., Wu E. Squeeze-and-Excitation Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2020;42(8):2011-2023. <https://doi.org/10.1109/TPAMI.2019.2913372>
10. Jaamour A., Myles C., Patel A., Chen S.-J., McMillan L., Harris-Birtill D. A divide and conquer approach to maximise deep learning mammography classification accuracies. *PLoS ONE*. 2023;18(5):e0280841. <https://doi.org/10.1371/journal.pone.0280841>
11. Jakkaladiki S.P., Maly F. Integrating hybrid transfer learning with attention-enhanced deep learning models to improve breast cancer diagnosis. *PeerJ Computer Science*. 2024;10:e1850. <https://doi.org/10.7717/peerj-cs.1850>
12. Kapila N., Glatki J., Rathi T. CNNtention: Can CNNs do better with Attention? *arXiv:2412.11657*. 2024. <https://doi.org/10.48550/arXiv.2412.11657>
13. Leong Y.S., et al. Microcalcification Discrimination in Mammography Using Deep Convolutional Neural Network: Towards Rapid and Early Breast Cancer Diagnosis. *Frontiers in Public Health*. 2022;10:875305. <https://doi.org/10.3389/fpubh.2022.875305>
14. Liao L., Aagaard E.M. An open codebase for enhancing transparency in deep learning-based breast cancer diagnosis utilizing CBIS-DDSM data. *Scientific reports*. 2024;14:27318. <https://doi.org/10.1038/s41598-024-78648-0>
15. Loizidou K., Elia R., Pitris C. Computer-aided breast cancer detection and classification in mammography: A comprehensive review. *Computers in Biology and Medicine*. 2023;153:106554. <https://doi.org/10.1016/j.compbiomed.2023.106554>
16. Mohamed H., Mabrouk M. S., Sharawy A. Computer aided detection system for micro calcifications in digital mammograms. *Computer Methods and Programs in Biomedicine*. 2014;116(3):226-235. <https://doi.org/10.1016/j.cmpb.2014.04.010>
17. Mohan S., Ravishankar M. Modified Contrast Limited Adaptive Histogram Equalization Based on Local Contrast Enhancement for Mammogram Images. In: Das V.V., Chaba Y. (eds.) *Mobile Communication and Power Engineering. AIM 2012. Communications in Computer and Information Science*. Vol. 296. Berlin, Heidelberg: Springer; 2013. p. 397-403. https://doi.org/10.1007/978-3-642-35864-7_60
18. Murcia-Gómez D., Rojas-Valenzuela I., Valenzuela O. Impact of Image Preprocessing Methods and Deep Learning Models for Classifying Histopathological Breast Cancer Images. *Applied Sciences*. 2022;12(22):11375. <https://doi.org/10.3390/app122211375>
19. 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>
20. 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>
21. Rasheed Z., et al. Integrating Convolutional Neural Networks with Attention Mechanisms for Magnetic Resonance Imaging-Based Classification of Brain Tumors. *Bioengineering*. 2024;11(7):701. <https://doi.org/10.3390/bioengineering11070701>
22. Shah S., Tembhurne J. Object detection using convolutional neural networks and transformer-based models: a review. *Journal of Electrical Systems and Information Technology*. 2023;10:54. <https://doi.org/10.1186/s43067-023-00123-z>
23. Tagnamas J., et al. Multi-task approach based on combined CNN-transformer for efficient segmentation and classification of breast tumors in ultrasound images. *Visual Computing for Industry, Biomedicine, and Art*. 2024;7:2. <https://doi.org/10.1186/s42492-024-00155-w>
24. Tan M., Le Q.V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In: *Proceedings of the 36th International Conference on Machine Learning, Long Beach, California, PMLR 97*. 2019. p. 6105-6114. Available at: <https://proceedings.mlr.press/v97/tan19a.html> (accessed 13.05.2025).
25. Wang L., Sun Y. Image classification using convolutional neural network with wavelet domain inputs. *IET Image Processing*. 2022;16(8):2037-2048. <https://doi.org/10.1049/ipr2.12466>
26. Wen X., et al. Breast cancer diagnosis: A systematic review. *Biocybernetics and Biomedical Engineering*. 2024;44(1):119-148. <https://doi.org/10.1016/j.bbe.2024.01.002>
27. Zarif S., Abdulkader H., Elaraby I., Alharbi A., Elkilani W.S., Pławiak P. Using hybrid pre-trained models for breast cancer detection. *PLoS ONE*. 2024;19(1):e0296912. <https://doi.org/10.1371/journal.pone.0296912>

Поступила 13.05.2025; одобрена после рецензирования 24.05.2025; принята к публикации 19.06.2025. Submitted 13.05.2025; approved after reviewing 24.05.2025; accepted for publication 19.06.2025.



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

Все авторы прочитали и одобрили окончательный вариант рукописи.

About the authors:

Hussein Alsajer, Postgraduate Student, Moscow Polytechnic University (107023 Moscow, Bolshaya Semyonovskaya str., 38), **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 (107023 Moscow, Bolshaya Semyonovskaya str., 38), Cand. Sci. (Eng.), Professor, **ORCID:** <https://orcid.org/0000-0001-9419-2282>, y_philippovich@mail.ru

All authors have read and approved the final manuscript.