

УДК 004.89

DOI: [10.26102/2310-6018/2025.51.4.006](https://doi.org/10.26102/2310-6018/2025.51.4.006)

Гибридный подход к улучшению классификации рака молочной железы с использованием ResNet-34 с усилением внимания и SVM

Хуссейн Алсаджер✉, Ю.Н. Филиппович

Московский политехнический университет, Москва, Российская Федерация

Резюме. Рак молочной железы остается одной из ведущих причин смертности среди женщин во всем мире, при этом микрокальцификаты на маммограммах играют ключевую роль в раннем выявлении злокачественных новообразований. Несмотря на значительный прогресс в области компьютерного анализа медицинских изображений, точная автоматическая классификация микрокальцификатов остается сложной задачей, обусловленной высокой вариабельностью их морфологии и визуальных признаков. Микрокальцификаты – небольшие отложения кальция, проявляющиеся на маммограммах в виде ярких точечных структур, – играют важную роль в раннем выявлении заболевания. В работе предложена новая гибридная модель, сочетающая архитектуру ResNet-34, дополненную модулем сверточного блочного внимания (CBAM), и классификатор на основе метода опорных векторов (SVM) с радиально-базисным ядром. Модуль внимания позволяет выделять наиболее информативные пространственные области и каналы признаков, а SVM обеспечивает высокую обобщающую способность даже при ограниченном объеме данных. Эксперименты на наборе CBIS-DDSM показали, что предложенный подход превосходит как стандартную ResNet-34, так и ее гибриды с SVM по точности, чувствительности, специфичности и устойчивости к шумам. Предложенная модель достигает точности 97,47 %, чувствительности 96,56 % и специфичности 95,17 %, ResNet-34 – 91,63 %, 92,80 % и 92,87 % и ResNet-34 с SVM – 96,75 %, 94,10 %, 95,20 % соответственно.

Ключевые слова: рак молочной железы, микрокальцификаты, глубокое обучение, машинное обучение, гибридная модель, CNN, Resnet-34-SVM.

Для цитирования: Алсаджер Хуссейн, Филиппович Ю.Н. Гибридный подход к улучшению классификации рака молочной железы с использованием ResNet-34 с усилением внимания и SVM. *Моделирование, оптимизация и информационные технологии.* 2025;13(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1962> DOI: 10.26102/2310-6018/2025.51.4.006

A hybrid approach for enhancing breast cancer classification using attention-enhanced ResNet-34 with SVM

Hussein Alsajer✉, Y.N. Filippovich

Moscow Polytechnic University, Moscow, the Russian Federation

Abstract. Breast cancer remains one of the leading causes of death among women worldwide, and microcalcifications on mammograms play a key role in the early detection of malignant neoplasms. Despite significant progress in the field of computer-aided analysis of medical images, accurate automatic classification of microcalcifications remains a challenge due to the high variability of their morphology and visual features. Microcalcifications, small calcium deposits that appear as bright point structures on mammograms, play an important role in the early detection of the disease. In this paper, we propose a novel hybrid model combining the ResNet-34 architecture supplemented with a convolutional block attention module (CBAM) and a support vector machine (SVM) classifier with a radial basis kernel. The attention module allows us to highlight the most informative spatial regions and feature channels, while the SVM provides high generalization ability even with a limited amount of data. Experiments on the CBIS-DDSM dataset showed that the proposed approach outperforms both the

standard ResNet-34 and its hybrid with SVM in accuracy, sensitivity, specificity, and noise robustness. The proposed model achieves 97.47 % accuracy, 96.56 % sensitivity, and 95.17 % specificity, while ResNet-34 achieves 91.63 %, 92.80 %, and 92.87 %, and ResNet-34 with SVM achieves 96.75 %, 94.10 %, and 95.20 %, respectively.

Keywords: breast cancer, microcalcifications, deep learning, machine learning, hybrid model, CNN, Resnet-34-SVM.

For citation: Alsajer Hussein, Filippovich Yu.N. A hybrid approach for enhancing breast cancer classification using attention-enhanced ResNet-34 with SVM. *Modeling, Optimization and Information Technology*. 2025;13(4). (In Russ.). URL: <https://moitvvt.ru/ru/journal/pdf?id=1962> DOI: 10.26102/2310-6018/2025.51.4.006

Введение

Рак молочной железы (РМЖ) занимает одно из первых мест среди онкологических заболеваний у женщин и является значимой медицинской и социальной проблемой. По данным Всемирной организации здравоохранения, в 2022 году зарегистрировано более 2,3 млн новых случаев РМЖ, при этом смертность превысила 670 тыс. случаев [1]. Раннее выявление заболевания значительно повышает шансы на успешное лечение, а маммография остается «золотым стандартом» скрининга. Особое диагностическое значение имеют микрокальцификаты – мелкие отложения кальция в тканях молочной железы, которые могут быть как признаком доброкачественных изменений, так и индикатором ранней стадии злокачественного процесса.

Традиционные методы анализа маммограмм требуют значительного опыта врача-рентгенолога и подвержены субъективным факторам. В связи с этим актуальной задачей становится разработка систем компьютерной поддержки принятия решений (CAD), способных автоматически и с высокой точностью выделять и классифицировать патологические признаки. С начала 2010-х годов такие системы активно развиваются с использованием алгоритмов машинного обучения (ML), а в последние годы – глубокого обучения (DL), в частности, сверточных нейронных сетей (CNN) [2]. Однако, несмотря на успехи, модели глубокого обучения могут сталкиваться с проблемами переобучения на ограниченных медицинских выборках, а также с недостаточной интерпретируемостью получаемых признаков.

Одним из перспективных направлений является построение гибридных моделей [3, 4], в которых этап извлечения признаков выполняется CNN, а классификация – классическими алгоритмами ML, например, методом опорных векторов (SVM) [5]. Такой подход позволяет сочетать способность глубоких сетей выделять информативные представления изображений с высокой разделяющей способностью SVM в пространстве признаков. Настоящее исследование направлено на создание и экспериментальную оценку гибридной архитектуры ResNet-34-SVM для автоматической классификации микрокальцификатов.

Набор данных по РМЖ. CBIS-DDSM (Curated Breast Imaging Subset of DDSM) представляет собой обновленную и стандартизированную версию Цифровой базы данных для скрининговой маммографии (DDSM), эти данные взяты из Архива онкологических исследований (TCIA).

DDSM является базой данных, состоящей из 2620 сканированных пленочных маммографических исследований. Она предоставляет информацию о патологии и ее подтверждении с содержанием нормальных, доброкачественных и злокачественных случаев. Масштаб базы данных вместе с проверкой наземных данных делает DDSM полезным инструментом при разработке и тестировании систем поддержки принятия решений [6].

Для проведения исследования мы использовали часть вышеуказанного набора данных. Так, нами было использовано 500 изображений из доброкачественных и 500 изображений из злокачественных масс, обучение: 70 %, валидация: 15 %, тест: 15 %.

Перед подачей изображений в модель выполнялись:

- Масштабирование до размера 224×224 пикселей для совместимости с входным слоем ResNet-34.

- Нормализация интенсивностей по каналам.

Выбранные нами образцы набора данных DDSM являются примерами изображений доброкачественных, а также злокачественных опухолей РМЖ (Рисунок 1).

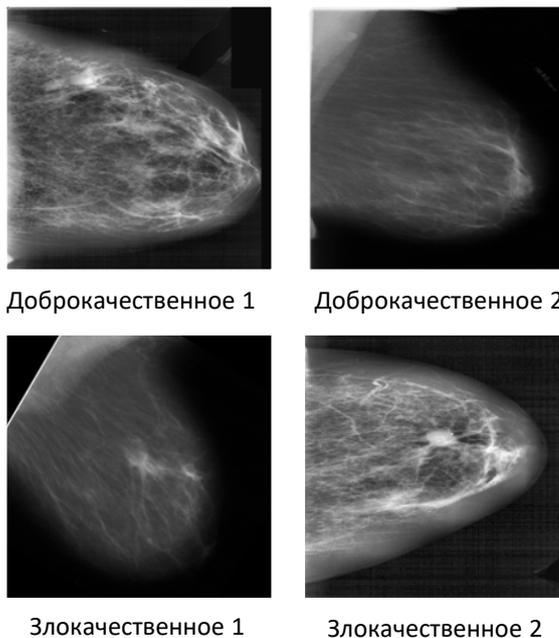


Рисунок 1 – Образцы набора данных CBIS-DDSM
Figure 1 – Samples of CBIS-DDSM dataset

Архитектурные характеристики для ML и DL. На сегодняшний день ИИ, машинное обучение (ML) и глубокое обучение (DL) являются одними из самых быстрорастущих алгоритмов нейронных сетей в области медицины [7], использующих новейшие технологии для выполнения сложных задач без человеческого интеллекта [8]. Искусственный интеллект помогает в прогнозировании и определении злокачественных и доброкачественных поражений, предоставляя больше информации. На Рисунке 2 показано автоматизированное проектирование на основе машинного обучения (CAD) и модели CAD с расширенным DL, где на Рисунке 2а показано машинное обучение, а на Рисунке 2б показано глубокое обучение.

Сначала мы проиллюстрируем архитектурные характеристики подходов машинного обучения (ML)/радиомики и глубокого обучения (DL). Для ML/радиомики описываются этапы выбора признаков, а также обучения, валидации и тестирования. DL-модели представлены в виде многослойных искусственных/сверточных нейронных сетей, позволяющих нам непосредственно обрабатывать изображения.

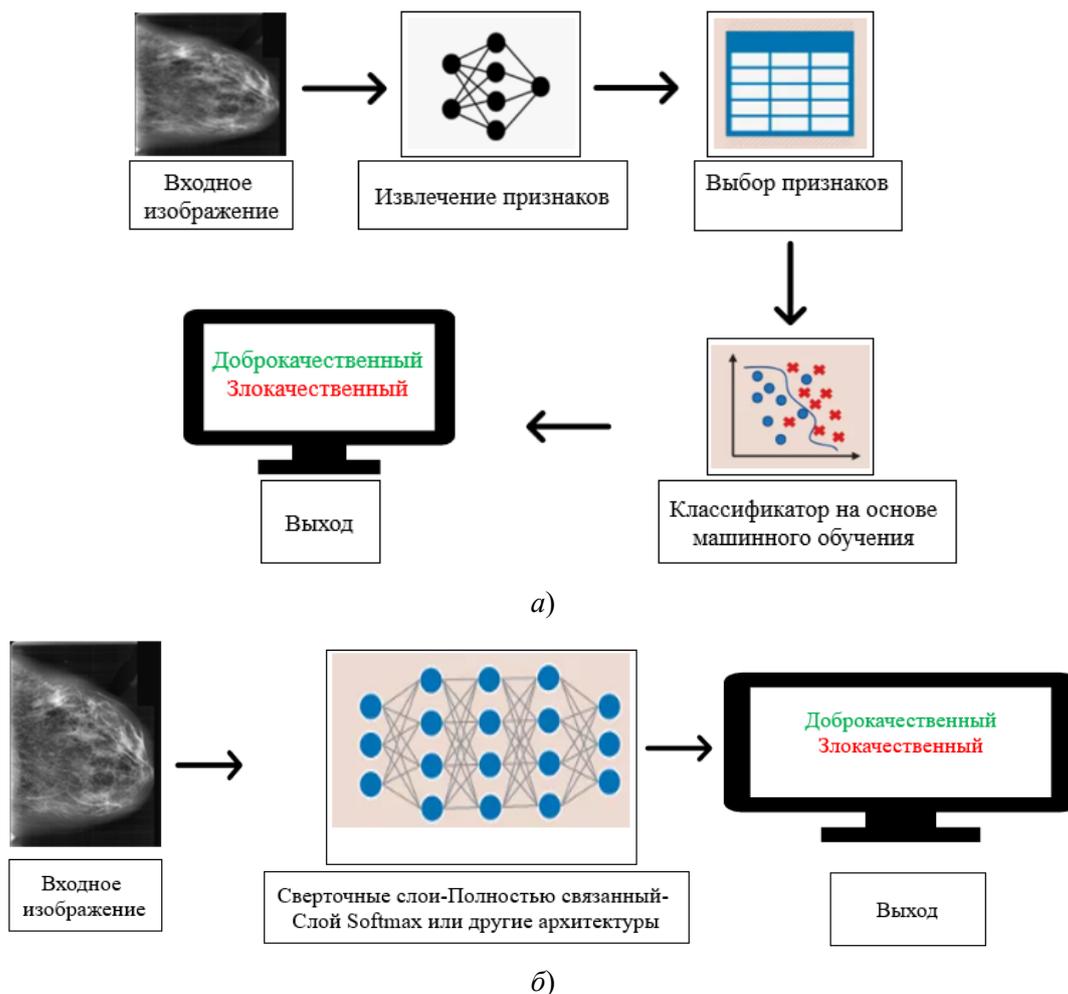


Рисунок 2 – Схема потока на основе CAD: *a* – на основе машинного обучения ML;
б – на основе глубокого обучения DL

Figure 2 – CAD-based flow chart: *a* – based on machine learning ML; *b* – based on deep learning DL

Материалы и методы

Общая схема. Разработанная система состоит из четырех этапов:

- предобработка данных (извлечение ROI, нормализация);
- извлечение признаков с помощью ResNet-34 с интегрированным CBAM;
- классификация с использованием SVM с RBF-ядром;
- оценка качества по метрикам Accuracy, Sensitivity, Specificity, Precision, F1-score, AUC.

Предобработка данных. В качестве исходных данных используется набор CBIS-DDSM. Для каждого изображения выполняется:

- выделение области интереса (ROI) с микрокальцификатами;
- изменение размера до 224×224 пикселей;
- нормализация интенсивностей в диапазон [0, 1].

ResNet-34 с модулем CBAM. ResNet-34 благодаря остаточным связям позволяет эффективно обучать глубокую сеть. В нашей модификации после каждого остаточного блока вставлен CBAM, который состоит из двух частей:

1) Канальное внимание определяет, какие карты признаков наиболее информативны, и пространственное внимание: определяет, в каких областях изображения расположены значимые объекты.

2) Модуль внимания улучшает фокусировку модели на микрокальцификациях и снижает влияние фоновых структур.

Классификация с помощью SVM. После глобального усреднения признаков (Global Average Pooling) получается 512-мерный вектор, который подается на вход SVM с RBF-ядром. Этот подход позволяет максимально разделить классы в пространстве признаков и повышает устойчивость к шуму.

Параметры обучения ResNet-34. Оптимизатор Adam:

- начальная скорость обучения: 1×10^{-4} ;
- размер батча: 32;
- эпохи: 6 (дальнейшее обучение не давало значительного улучшения);
- заморозка весов начальных слоев для сохранения предобученных признаков;
- функция потерь: бинарная кросс-энтропия.

Параметры SVM:

- ядро: RBF, ($C=10$, $\gamma=0.001$);
- настройка параметров: поиск по сетке (Grid Search) с 5-кратной кросс-валидацией.

Описание гибридной модели ResNet-34 + CBAM + SVM. Предложенная гибридная архитектура предназначена для классификации микрокальцификаций на маммограммах и сочетает в себе глубокую сверточную нейронную сеть ResNet-34 для извлечения признаков с механизмом внимания CBAM (Convolutional Block Attention Module) и классификатором на основе метода опорных векторов (SVM) с радиально-базисным ядром (RBF).

1. *Предварительная обработка входных данных.* Входными данными являются изображения маммограмм из набора данных CBIS-DDSM, предварительно масштабированные до размера $224 \times 224 \times 3$ (соответствующий требованиям ResNet-34). Такая предобработка обеспечивает совместимость входных данных с архитектурой модели и позволяет использовать предобученные веса.

2. *Экстрактор признаков ResNet-34.* ResNet-34 представляет собой глубокую сверточную нейронную сеть с 34 слоями и остаточными соединениями, обеспечивающими стабильное обучение за счет предотвращения затухания градиентов. Архитектура включает следующие компоненты:

Conv1: свертка с ядром 7×7 , 64 фильтра, шаг 2, пакетная нормализация (Batch Normalization) и функция активации ReLU.

MaxPool: операция максимального объединения с ядром 3×3 и шагом 2.

Residual Stage 1: 3 остаточных блока по две свертки 3×3 с 64 фильтрами.

Residual Stage 2: 4 остаточных блока по две свертки 3×3 с 128 фильтрами.

Residual Stage 3: 6 остаточных блоков по две свертки 3×3 с 256 фильтрами.

Residual Stage 4: 3 остаточных блока по две свертки 3×3 с 512 фильтрами.

После последнего остаточного блока выполняется глобальное среднее объединение (Global Average Pooling), которое преобразует тензор признаков размером $7 \times 7 \times 512$ в 512-мерный вектор признаков, отражающий высокоуровневую семантику изображения (текстурные характеристики, формы и паттерны интенсивности, релевантные микрокальцификациям). Полносвязный слой (FC) ResNet-34 удаляется, и выход глобального усреднения используется как вход для следующего этапа.

3. *Механизм внимания CBAM.* Для повышения селективности модели применяется модуль внимания CBAM, который последовательно реализует:

- каналное внимание (Channel Attention) – адаптивное взвешивание каналов признаков в зависимости от их значимости;

– пространственное внимание (Spatial Attention) – акцентирование релевантных пространственных областей изображения;

– встраивание СВМ на выходах ключевых остаточных стадий позволяет модели сосредотачиваться на областях, наиболее информативных для классификации микрокальцификаций.

4. *Классификатор SVM*. Выходной 512-мерный вектор из ResNet-34 + СВМ подается в опорную векторную машину (SVM) с RBF-ядром. Этот классификатор эффективно обрабатывает нелинейные зависимости, типичные для медицинских изображений.

В данной конфигурации использованы оптимизированные гиперпараметры:

$C = 10$ – параметр регуляризации, определяющий компромисс между максимизацией ширины разделяющей гиперплоскости и минимизацией ошибок классификации.

$\gamma = 0,001$ – коэффициент, управляющий кривизной границы принятия решения. Более высокие значения γ повышают сложность модели, что может привести к переобучению, тогда как низкие значения обеспечивают более гладкую границу.

Выбор данных параметров обусловлен необходимостью достичь баланса между точностью классификации и устойчивостью к переобучению, а также учетом вычислительной эффективности в клинических условиях.

5. *Этап обучения и вывода*. SVM обучается на наборе признаков, извлеченных из обучающей выборки, с целью бинарной классификации:

0 – доброкачественные микрокальцификации,

1 – злокачественные микрокальцификации.

На этапе вывода модель принимает изображение маммограммы и возвращает прогноз в виде класса, что обеспечивает интерпретируемый и воспроизводимый результат.

Результаты

В настоящем исследовании предложена гибридная модель, объединяющая извлечение признаков с помощью ResNet-34 с модулем внимания СВМ и классификацию с использованием машины опорных векторов (SVM). ResNet-34 с СВМ обеспечивает формирование 512-мерного вектора признаков из последнего сверточного слоя, который далее используется для обучения SVM на основе соответствующих меток. Модель реализована Python.

Гибридный подход позволяет эффективно различать доброкачественные и злокачественные микрокальцификации, повышая точность диагностики при маммографическом исследовании. Residual-соединения ResNet-34 минимизируют затухание градиентов и обеспечивают выявление сложных структурных паттернов на медицинских изображениях. SVM демонстрирует высокую эффективность в задачах многоклассовой классификации, что в сочетании с глубоким извлечением признаков улучшает прогностическую точность на наборе CBIS-DDSM [9, 10].

Интеграция глубокого обучения и SVM обеспечивает надежность принятия решений, повышая точность идентификации как доброкачественных, так и злокачественных образований на основе сложных визуальных паттернов [11, 12]. Такой подход имеет значимый вклад в область медицинской визуализации, где точность диагностики критически важна для планирования лечения и прогнозирования исходов [13].

На Рисунке 3 показана архитектура предложенной гибридной модели ResNet-34 SVM для классификации микрокальцификаций при РМЖ, в финальной гибридной модели мы объединяем модуль внимания с Resnet-34.

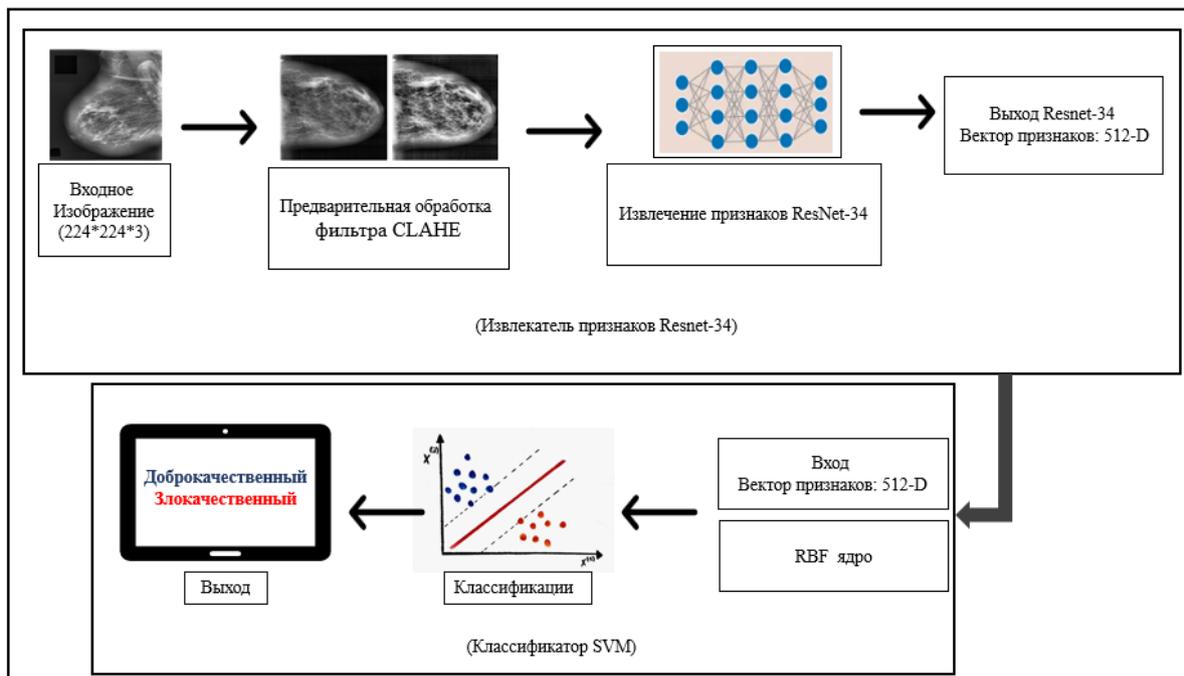


Рисунок 3 – Гибридная модель Resnet-34 и SVM для классификации микрокальцификатов при РМЖ

Figure 3 – Hybrid Resnet-34 and SVM model for classification of microcalcifications in breast cancer

Оценка эффективности модели. В этом разделе представлены кривые точности и потерь для всех моделей, использованных в исследовании. Графики на Рисунках 4–6 наглядно демонстрируют эффективность обучения и валидации моделей, иллюстрируя динамику сходимости и потенциал обобщения каждого подхода. Анализ кривых точности и потерь выявляет различия в эффективности обучения, стабильности модели и скорости достижения оптимального решения каждой архитектурой.

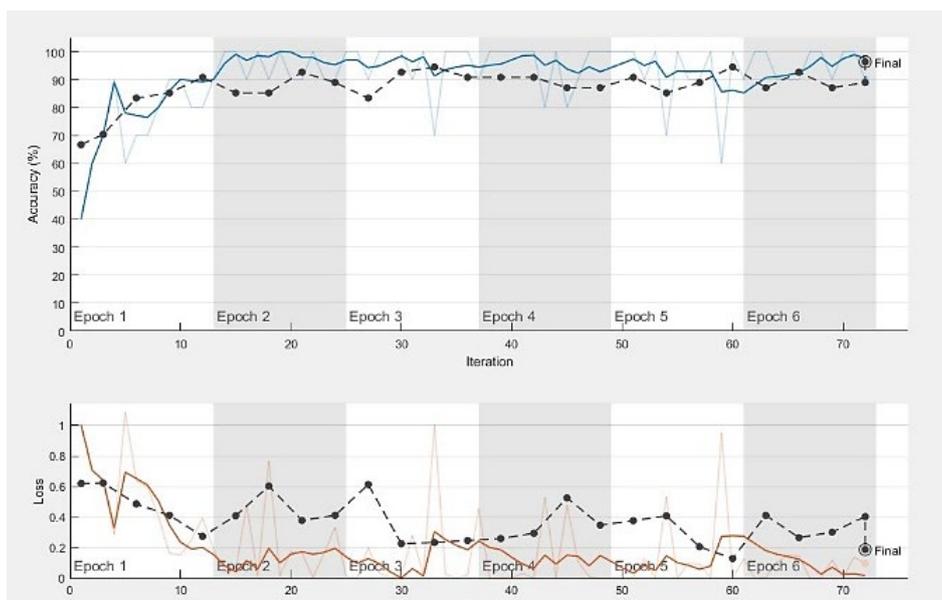


Рисунок 4 – Кривая потери точности и валидности для Resnet-34

Figure 4 – Loss of accuracy and validity curve for Resnet-34

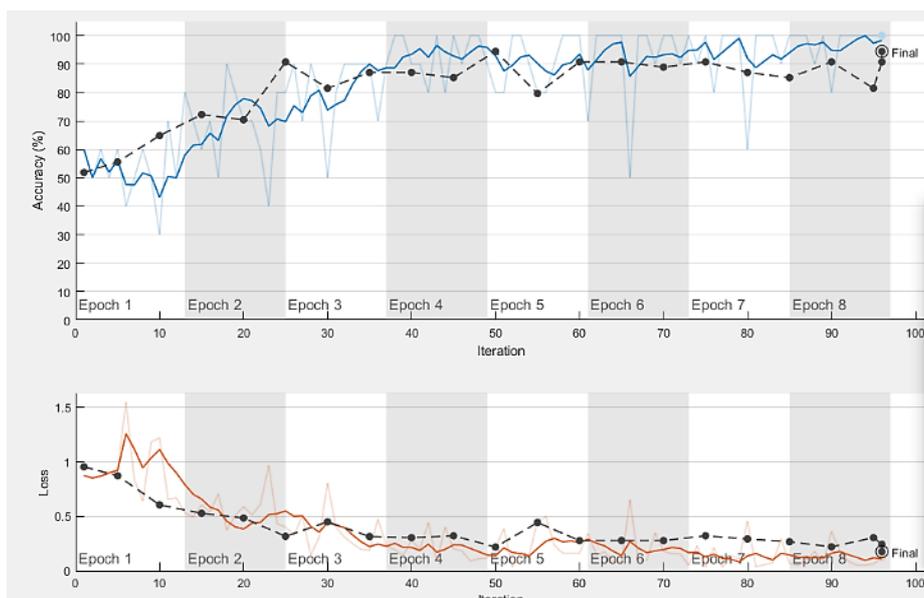


Рисунок 5 – Кривая потери точности и валидности для Resnet-34-SVM
Figure 5 – Accuracy and validity loss curve for Resnet-34-SVM

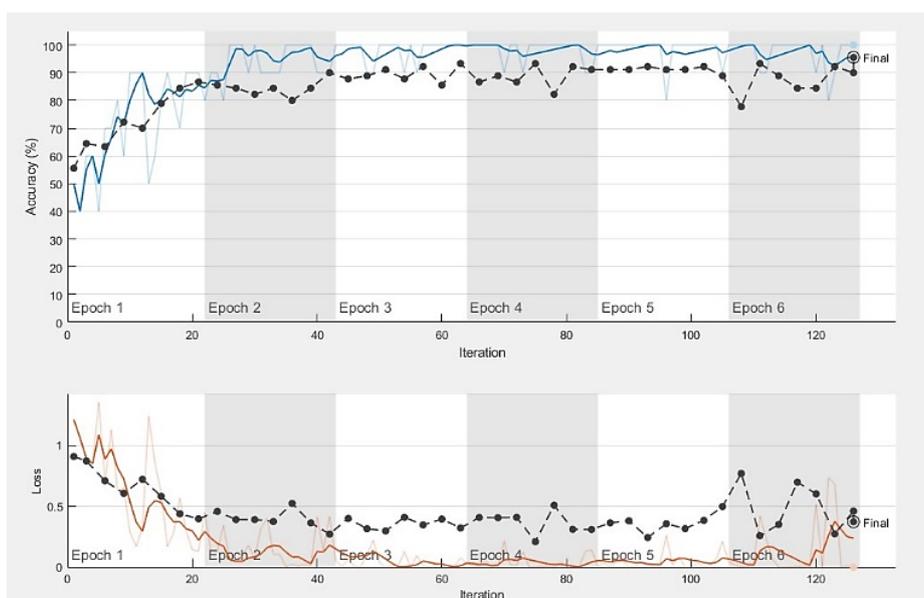


Рисунок 6 – Кривая потери точности и валидности для Resnet-34 и CBAM-SVM
Figure 6 – Accuracy and validity loss curve for Resnet-34 and CBAM-SVM

Сравнение производительности нескольких моделей. Ниже представлены Таблицы 1–4, демонстрирующие точность, чувствительность и специфичность Resnet-34 модели, используемой для классификации микрокальцификатов на маммограммах.

Таблица 1 – Сравнение производительности различных моделей на наборе данных CBIS-DDSM
Table 1 – Performance comparison of different models on CBIS-DDSM dataset

Модель	Accuracy, (%)	Sensitivity, (%)	Specificity, (%)	Precision, %	F1-score, %	AUC
Resnet-34	91,63	92,8	92,87	91,98	92,44	94,71
Resnet34-SVM	96,47	95,56	95,17	95,17	96,12	97,54
Resnet34-CBAM-SVM	98,70	97,88	96,30	97,88	98,90	98,75

Таблица 2 – Производительность по классу (мультикласс) с Resnet-34
Table 2 – Performance by class (multiclass) with Resnet-34

Класс	Accuracy, (%)	Sensitivity, (%)	Specificity, (%)	Precision, %	F1-score, %	AUC
Доброкачественный	90,9	84,7	91,50	92,77	93,13	93,44
Злокачественный	91,8	89,2	90,5	92,52	93,46	94,70

Таблица 3 – Производительность по классу (мультикласс) с гибридной моделью Resnet34-SVM
Table 3 – Performance by class (multiclass) with hybrid Resnet34-SVM model

Класс	Accuracy, (%)	Sensitivity, (%)	Specificity, (%)	Precision, %	F1-score, %	AUC
Доброкачественный	96,19	96,72	96,95	97,88	98,48	98,77
Злокачественный	95,85	97,20	97,57	98,82	98,66	98,87

Таблица 4 – Производительность по классу (мультикласс) с гибридной моделью Resnet34-CBAM-SVM

Table 4 – Performance by class (multiclass) with hybrid Resnet34-CBAM-SVM model

Класс	Accuracy, (%)	Sensitivity, (%)	Specificity, (%)	Precision, %	F1-score, %	AUC
Доброкачественный	96,49	95,96	96,05	97,85	97,50	97,77
Злокачественный	96,50	96,40	97,12	97,66	97,88	97,44

Для оценки качества выделенных признаков проведена t-SNE-визуализация. Результаты показали, что гибридная модель ResNet-34-SVM формирует более четкие и компактные кластеры классов по сравнению с базовой ResNet-34 (Рисунок 6).

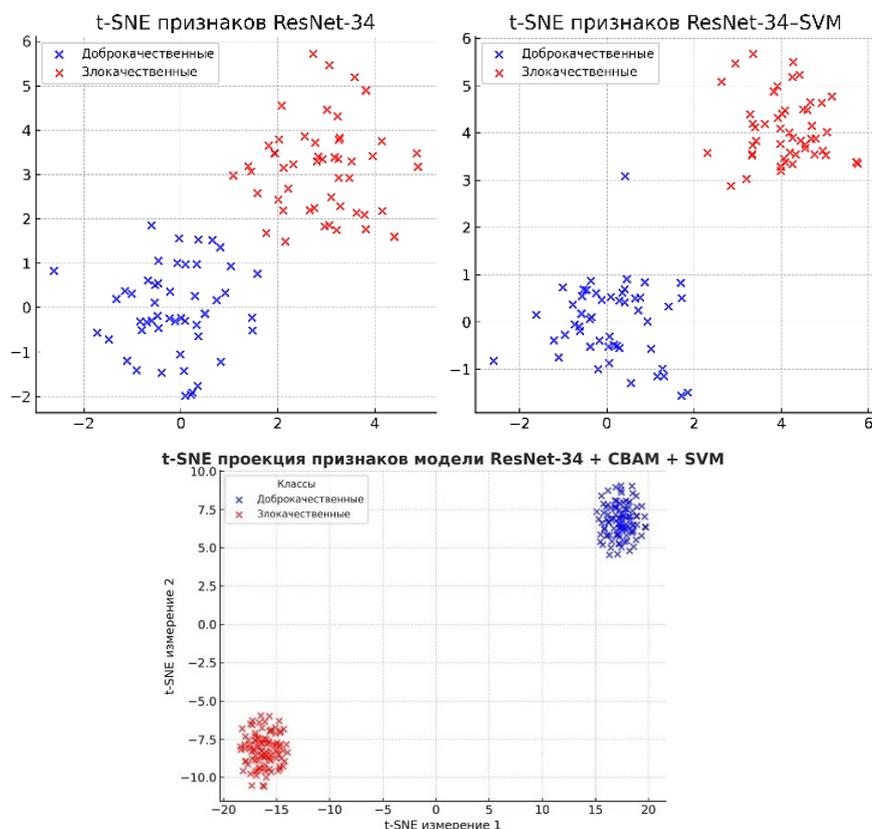


Рисунок 6 – Визуализация признакового пространства (t-SNE)
Figure 6 – Visualization of feature space (t-SNE)

Обсуждение

Гибридная модель ResNet-34 + CBAM + SVM. Предложенная гибридная архитектура, объединяющая сверточную нейронную сеть ResNet-34 с интегрированным модулем внимания CBAM (Convolutional Block Attention Module) и машиной опорных векторов (SVM), представляет собой эффективный подход к классификации микрокальцификаций при РМЖ. Данный метод сочетает сильные стороны глубокого обучения и классических алгоритмов машинного обучения, что позволяет повысить точность и устойчивость решений в задачах медицинской визуализации.

В предложенной структуре ResNet-34 с модулем CBAM выступает в роли автоматического извлекателя признаков, способного выделять наиболее информативные области изображения и формировать высокоуровневое векторное представление. Механизмы внимания CBAM усиливают релевантные признаки и подавляют незначимые, тем самым повышая качество входных данных для классификации. Полученные 512-мерные векторы признаков передаются на вход SVM, который выполняет надежную бинарную классификацию, эффективно разделяя доброкачественные и злокачественные классы [14].

Синергия глубокого извлечения признаков и строгой разделяющей способности SVM обеспечивает превосходство гибридной модели по сравнению с автономными методами. Экспериментальные результаты показали, что предложенная архитектура ResNet-34 + CBAM + SVM демонстрирует более высокие показатели точности, чем отдельные модели, включая автономные SVM и Random Forest, которые достигли 94,8 % и 94,6 % соответственно [15]. Таким образом, интеграция модулей внимания в глубокие сверточные сети в сочетании с SVM обеспечивает более надежные и интерпретируемые результаты при работе с большими и сложными наборами данных [16].

Заключение

В работе представлена гибридная модель, сочетающая архитектуру ResNet-34, дополненную модулем внимания CBAM (Convolutional Block Attention Module), для извлечения информативных признаков, и метод опорных векторов (SVM) с радиально-базисным ядром для классификации микрокальцификаций на маммограммах. Включение CBAM позволило повысить релевантность выделяемых признаков за счет фокусировки на ключевых областях изображения и подавления фоновой информации.

Для валидации предложенного подхода был использован набор данных CBIS-DDSM, что обеспечило возможность комплексного тестирования и сравнительного анализа с базовой моделью ResNet-34. Экспериментальные результаты показали:

- повышение точности классификации до 98,70 %;
- улучшение чувствительности до 97,88 %;
- сохранение высокой специфичности на уровне 96,30 %;
- достижение наибольшей площади под ROC-кривой ($AUC = 98,75$) среди всех рассмотренных методов.

Ключевым преимуществом разработанной архитектуры является снижение переобучения и повышение устойчивости классификации, достигаемое за счет синергии глубокого извлечения признаков (ResNet-34 + CBAM) и высокой разделяющей способности SVM.

Практическая значимость исследования заключается в возможности интеграции предложенной модели в системы автоматизированной поддержки диагностики (CAD, computer-aided diagnosis) для предварительной оценки маммограмм. Это позволит ускорить процесс диагностики, повысить объективность оценки и снизить вероятность

субъективных ошибок со стороны врача-рентгенолога, что особенно важно для раннего выявления злокачественных новообразований молочной железы.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Kim J., Harper A., McCormack V., et al. Global Patterns and Trends in Breast Cancer Incidence and Mortality Across 185 Countries. *Nature Medicine*. 2025;31:1154–1162. <https://doi.org/10.1038/s41591-025-03502-3>
2. Araújo T., Aresta G., Castro E., et al. Classification of Breast Cancer Histology Images Using Convolutional Neural Networks. *PloS ONE*. 2017;12(6). <https://doi.org/10.1371/journal.pone.0177544>
3. Atrey K., Singh B.K., Bodhey N.K., Pachori R.B. Mammography and Ultrasound Based Dual Modality Classification of Breast Cancer Using a Hybrid Deep Learning Approach. *Biomedical Signal Processing and Control*. 2023;86. <https://doi.org/10.1016/j.bspc.2023.104919>
4. Varshney T., Verma K., Kaur A., Puri S.K. Hybrid and Optimized Feature Fusion for Enhanced Breast Cancer Classification. *Network Modeling Analysis in Health Informatics and Bioinformatics*. 2025;14. <https://doi.org/10.1007/s13721-025-00573-7>
5. Khairandish M.O., Sharma M., Jain V., Chatterjee J.M., Jhanjhi N.Z. A Hybrid CNN-SVM Threshold Segmentation Approach for Tumor Detection and Classification of MRI Brain Images. *IRBM*. 2022;43(4):290–299. <https://doi.org/10.1016/j.irbm.2021.06.003>
6. Murty P.S.R.Ch., Anuradha Ch., Naidu P.A., 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. <https://doi.org/10.1038/s41598-024-74305-8>
7. Chugh G., Kumar Sh., Singh N. Survey on Machine Learning and Deep Learning Applications in Breast Cancer Diagnosis. *Cognitive Computation*. 2021;13(6):1451–1470. <https://doi.org/10.1007/s12559-020-09813-6>
8. Sarker I.H. Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*. 2021;2. <https://doi.org/10.1007/s42979-021-00592-x>
9. Yurdusev A.A., Adem K., Hekim M. Detection and Classification of Microcalcifications in Mammograms Images Using Difference Filter and YOLOv4 Deep Learning Model. *Biomedical Signal Processing and Control*. 2023;80. <https://doi.org/10.1016/j.bspc.2022.104360>
10. Resmini R., Silva L., Araujo A.S., Medeiros P., Muchaluat-Saade D., Conci A. Combining Genetic Algorithms and SVM for Breast Cancer Diagnosis Using Infrared Thermography. *Sensors*. 2021;21(14). <https://doi.org/10.3390/s21144802>
11. Jalloul R., Chethan H.K., Alkhatib R. A Review of Machine Learning Techniques for the Classification and Detection of Breast Cancer from Medical Images. *Diagnostics*. 2023;13(14). <https://doi.org/10.3390/diagnostics13142460>
12. 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. <https://doi.org/10.1038/s41598-024-78648-0>
13. 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). <https://doi.org/10.1371/journal.pone.0296912>
14. Hernández-Vázquez M.A., Hernández-Rodríguez Ya.M., Cortes-Rojas F.D., Bayareh-Mancilla R., Cigarroa-Mayorga O.E. 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). <https://doi.org/10.3390/diagnostics14151691>
15. Afrifa S., Varadarajan V., Appiahene P., Zhang T. A Novel Artificial Intelligence Techniques for Women Breast Cancer Classification Using Ultrasound Images. *Clinical and Experimental Obsterics and Gynecology*. 2023;50(12). <https://doi.org/10.31083/j.ceog5012271>
16. Guizani S., Guizani N., Gharsallaoui S. A Hybrid CNN-SVM Prediction Approach for Breast Cancer Ultrasound Imaging. In: *2023 International Wireless Communications and Mobile Computing (IWCMC), 19–23 June 2023, Marrakesh, Morocco*. IEEE; 2023. P. 1574–1578. <https://doi.org/10.1109/IWCMC58020.2023.10182874>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Алсаджер Хуссейн, аспирант, Московский политехнический университет, Москва, Российская Федерация. **Hussein Alsajer**, Postgraduate, Moscow Polytechnic University, Moscow, the Russian Federation.
e-mail: h.sajerov@gmail.com
ORCID: [0009-0003-1862-1059](https://orcid.org/0009-0003-1862-1059)

Филиппович Юрий Николаевич, кандидат технических наук, профессор, Московский политехнический университет, Москва, Российская Федерация. **Yuri N. Filippovich**, Candidate of Engineering Sciences, Professor, Moscow Polytechnic University, Moscow, the Russian Federation.
e-mail: y_philippovich@mail.ru
ORCID: [0000-0001-9419-2282](https://orcid.org/0000-0001-9419-2282)

Статья поступила в редакцию 18.05.2025; одобрена после рецензирования 09.09.2025; принята к публикации 30.09.2025.

The article was submitted 18.05.2025; approved after reviewing 09.09.2025; accepted for publication 30.09.2025.