

## Сравнительный анализ сверточных нейронных сетей для классификации аномалий молочной железы

Х. Диаз-Эскобар\*, В.И. Кобер<sup>\*\*,\*\*\*</sup>, В.Н. Карнаухов<sup>\*\*</sup>, М.Г. Мозеров<sup>\*\*</sup>

\* Центр Научных исследований и высшего образования, Энсенада, 22860, Мексика

\*\* Институт проблем передачи информации, Российская академия наук, Москва, Россия

\*\*\* Челябинский государственный университет, Челябинск, Россия

Поступила в редколлегию 17.02.2023

**Аннотация**—Системы компьютерной диагностики используются радиологами в качестве второго интерпретатора для обнаружения рака молочной железы в цифровой маммографии. Однако, для каждого истинно положительного рака, обнаруженного системой компьютерной диагностики, эксперт должен пересмотреть большое количество ложных прогнозов, чтобы избежать ненужной биопсии. Традиционный подход к созданию таких систем заключается в выборе и расчете признаков интересующих объектов из исходных данных с последующим подбором модели для их классификации с помощью машинного обучения. Машинное обучение и особенно глубокое обучение используются для анализа маммограмм. Большинство предложенных до сих пор моделей обучаются на небольшом количестве данных и не обладают высокой надежностью. В этой работе сравниваются несколько моделей глубокого обучения для классификации доброкачественных и злокачественных образований на цифровых маммограммах. Этап предварительной обработки предназначен для удаления шума и извлечения признаков с использованием локальной информации о фазе изображения. Затем для классификации цифровой маммографии используется глубокое обучение. Экспериментальные результаты представлены с использованием нескольких баз данных и оценены с помощью нескольких критериев качества.

**КЛЮЧЕВЫЕ СЛОВА:** маммография, система компьютерной диагностики, машинное обучение, нейронные сети, фазовые признаки.

DOI: 10.53921/18195822\_2023\_23\_1\_1

### ВВЕДЕНИЕ


Рак молочной железы (РМЖ) является наиболее распространенным видом рака и одной из основных причин смерти среди женщин во всем мире. В 2020 году во всем мире было диагностировано более 2,2 миллиона случаев рака молочной железы [1]. Однако раннее выявление и правильное лечение позволяют увеличить ожидаемую продолжительность жизни и вероятность излечения. Несмотря на то, что существуют различные способы выявления рака молочной железы, такие как магнитно-резонансная томография, томосинтез, ультразвуковое исследование, рентгеновская маммография продолжает оставаться наиболее широко используемым способом раннего выявления патологий молочной железы. Было показано, что маммография снижает смертность от 20% до 40% для женщин в возрасте от 50 до 69 лет [2]. К сожалению, эти рентгенологические изображения трудно интерпретировать, и требуется заключение эксперта. Тем не менее, считается, что опытные рентгенологи выявляют только 84% злокачественных опухолей; в то же время оставшиеся 16% пропускаются из-за ограничений зрения человека, плотной ткани молочной железы или шума на изображении [3]. Цифровая маммография использует специальный электронный детектор рентгеновского излучения, который преобразует сигнал в цифровое изображение для компьютерного скрининга (визуальное обследование

для выявления заболеваний). Для обнаружения патологий молочной железы используются две ее проекции: косая медиалатеральная (MLO) и левая/правая краниокаудальная (CC) проекции [4]. Стандартное описание маммограмм [5] включает в себя следующую информацию: показание к проведению обследования (скрининг; диагностическое исследование; контрольное наблюдение); описание структуры молочных желез по рекомендации Американской Коллегии Радиологов (ACR); описание патологических признаков с использованием стандартной терминологии (объемное образование, асимметрия, нарушение архитектоники, кальцификация, сопутствующие признаки); сравнение с предыдущими исследованиями (при наличии); вывод/заключение с выставлением итоговой категории по шкале BI-RADS [6] — система интерпретации и протоколирования визуализации молочной железы. Основной целью создания системы BIRADS была разработка унифицированного языка/терминов интерпретации результатов осмотра молочных желез, классификация выявляемых радиологических признаков и адекватных рекомендаций к дальнейшей лечению. По данным ACR объемное образование определяется как область поражения, видимая, по крайней мере, в двух разных проекциях. Объемные образования имеют разную плотность, края и форму. Образования округлой и овальной формы с гладкими краями обычно указывают на доброкачественные изменения, а вот резкие и неровные границы указывают на злокачественное образование. Для облегчения задачи врачей по обнаружению патологий молочной железы на ранних стадиях, в настоящее время активно разрабатываются методы и алгоритмы для систем компьютерной диагностики (СКД). Такие системы используются радиологами для обнаружения рака молочной железы в цифровой маммографии, позволяя выявлять возможных кандидатов на наличие подозрительной ткани там, где человеческий глаз не может их обнаружить. Однако на каждый истинно положительный рак, обнаруженный системой СКД, приходится большое количество ложных прогнозов, которые эксперт должен пересмотреть, чтобы избежать ненужной биопсии [7]. В настоящее время модели глубокого обучения активно используются для анализа цифровой маммографии [8], [9], [10], [11], [12]. Однако большинство предложенных до сих пор моделей обучаются на одной базе данных и не обладают высокой надежностью. Это связано с тем, что артефакты изображения, контрастность и разрешение постоянно отличаются от одного набора данных к другому. Исследования также показали, что высокая плотность молочной железы может снизить точность маммографии, маскируя опухоли [13] и является надежным биомаркером повышенного риска рака молочной железы. Маскировка происходит, когда перекрывающаяся ткань молочной железы скрывает раковую опухоль, что затрудняет или даже делает невозможным для экспертов обнаружение злокачественных опухолей при регулярном маммографическом скрининге на ранних стадиях. В этой работе несколько моделей глубокого обучения были оценены для бинарной маммографической классификации. Этап предварительной обработки предназначен для удаления шума, изменения размера изображений до одинакового размера и извлечения функций с использованием информации о локальной фазе изображения для извлечения структурной информации изображения и устранения различий из-за изменения контраста и разрешения. Затем для бинарной классификации используется подход глубокого обучения. Экспериментальные результаты представлены с использованием нескольких баз данных по цифровой маммографии. Статья организована следующим образом: в разделе 2 описан предлагаемый подход к построению СКД, в разделе 3 представлены и обсуждены полученные результаты экспериментов с помощью компьютерного моделирования, и раздел 4 суммирует наши выводы.

## 1. КЛАССИФИКАЦИЯ АНОМАЛИЙ МОЛОЧНОЙ ЖЕЛЕЗЫ

Предварительная обработка маммографических изображений является необходимой подготовкой данных для обучения и использования в модели нейронной сети с целью стандар-

тизации входа в нейронную сеть. Она необходима для улучшения качества изображений, для устранения технологических меток и шума, для улучшения извлечения особенностей и закономерностей на изображениях. Так как большинство предварительно обученных моделей нейронных сетей используют размер изображения  $224 \times 224$  (ширина  $\times$  высота) пикселей, то для изображений других размеров осуществлялась стандартизация размеров, при этом для повышающей дискретизации использовалась кубическая интерполяция, а для понижающей дискретизации интерполяционная формула Гаусса, которая дает лучшие результаты. На этапе предварительной обработки размеры изображений были изменены до  $224 \times 224$  пикселей с последующей коррекцией контраста и яркости ( $\alpha = 3, \beta = 100$ ) для усиления разницы между передним планом изображения и фоном. Затем применялась глобальная пороговая обработка изображения и выполнялись морфологические операции (расширение и эрозия) для устранения технологических меток маммограммы и других элементов шума [12]. Полученная бинарная маска была умножена на исходную маммограмму, что дало откорректированное изображение маммограммы без технологической метки. Пример маммографического изображения на разных этапах предварительной обработки показан на Рис.1



**Рис. 1.** Пример маммографического изображения на разных этапах предварительной обработки: а) — исходное изображение; б) — после глобальной пороговой обработки; в) — бинарная маска; г) — откорректированное изображение без метки.

После удаления меток на изображениях производится обнаружение и извлечение образований молочной железы с использованием моногенного сигнала. В работе [14] предложена локальная энергетическая модель восприятия границ объектов, линий и теней. Согласно этой модели, визуальная система человека способна определять квадратную и трапециевидную форму волны с использованием информации о фазе, и можно доказать, что максимум энергетической функции происходит в точках с максимальной фазовой конгруэнтностью [15]. Была предложена безразмерная мера фазовой конгруэнтности в каждой точке изображения [16], [17], где значение фазовой конгруэнтности — значимость признака в данной точке; единица означает наиболее значимый признак, и ноль — самое низкое значение признака. В работе [18] предложена новая концепция двумерного аналитического сигнала, называемым моногенный сигнал.

Пусть  $H_e \in L2$  и  $H_o \in L2$  — базовые операторы модели с равными амплитудами спектра и ортогональными фазами;  $H_o$  — преобразование Гильберта  $H_e$ . Локальная энергетическая функция определяется как

$$E(x) = \sqrt{(H_e(x) * f(x))^2 + (H_o(x) * f(x))^2}, \quad (1)$$

где  $f(x) \in L^2$  — периодический сигнал,  $*$  — оператор свертки. Локальная энергетическая функция локализует признаки на изображении, но не содержит информации о типе признака. Чтобы определить тип признака, необходимо вычислить функцию аргумента, определенную как

$$\varphi(x) = \arctan \left( \frac{H_e(x) * f(x)}{H_o(x) * f(x)} \right). \quad (2)$$

Периодическая функция  $f(x)$  может быть разложена в ряд Фурье:

$$f(x) = \sum_n A_n \cos(\varphi_n(x)), \quad (3)$$

где  $A_n$  — амплитуда  $n$ -ой компоненты в разложении Фурье, и  $\varphi_n(x) = n\omega x + \phi(x)$  — локальная фазовая функция. Функция фазовой конгруэнтности определяется как

$$PC(x) = \max_{\varphi(x) \in [0, 2\pi]} \frac{\sum_n A_n \cos(\varphi(x) - \bar{\varphi}(x))}{\sum_n A_n}, \quad (4)$$

где  $\bar{\varphi}(x)$  — взвешенное среднее значение локальной фазовой функции по всем Фурье компонентам в данной точке. Моногенный сигнал определяется как комбинация двумерного сигнала и его преобразование Риеса первого порядка. Пусть  $R_x; R_y$  — передаточные функции преобразования Риеса первого порядка в частотной области:

$$R_x(u, v) = i \frac{u}{\sqrt{u^2 + v^2}} = F_r \left( \frac{x}{2\pi(x^2 + y^2)^{\frac{3}{2}}} \right), \quad (5)$$

$$R_y(u, v) = i \frac{v}{\sqrt{u^2 + v^2}} = F_r \left( \frac{y}{2\pi(x^2 + y^2)^{\frac{3}{2}}} \right) \quad (6)$$

где  $F_r$  — оператор преобразования Фурье. Моногенный сигнал формально определяется как

$$F_M(u, v) = F(u, v) + i\mathbf{R} \cdot F(u, v), \quad (7)$$

где  $F(u, v)$  — Фурье преобразование  $f(x, y)$  и  $R = (R_x, R_y)$ . Для обеспечения инвариантности к масштабированию предлагается использовать линейное представление Пуассона [19], так как оно связано с моногенным сигналом. Это представление  $f_p(x, y, s)$  определяется как свертка изображения  $f(x, y)$  с ядром Пуассона, следующим образом:

$$f_p(x, y, s) = \frac{s}{2\pi(x^2 + y^2 + s^2)} * f(x, y) = F_r^{-1} \left( e^{-2\pi s \sqrt{u^2 + v^2}} \cdot F(u, v) \right), \quad (8)$$

где  $s$  — параметр масштаба, который контролирует разрешение изображения,  $F_r^{-1}$  — оператор обратного преобразования Фурье. Представление Пуассона в частотной области после полосой фильтрации задается следующим образом:

$$F_{bp}(u, v) = \left( e^{-2\pi s_0 \lambda^k \sqrt{u^2 + v^2}} - e^{-2\pi s_0 \lambda^{k-1} \sqrt{u^2 + v^2}} \right) \cdot F(u, v), \quad (9)$$

где  $\lambda \in (0, 1)$  указывает относительную ширину полосы частот,  $s_0$  — параметр самого грубого масштаба, а  $k \in \mathbb{N}$  обозначает номер полосы пропускания [16]. Тогда представление Пуассона моногенного сигнала имеет вид:

$$F_{Mbp}(u, v) = F_{bp}(u, v) + i\mathbf{R} \cdot F_{bp}(u, v), \quad (10)$$

где  $f_p(x, y) = F_r^{-1}\{F_{bp}(u, v)\}$ ,  $f_x(x, y) = F_r^{-1}\{R_x(u, v)F_{bp}(u, v)\}$ ,  $f_y(x, y) = F_r^{-1}\{R_y(u, v)F_{bp}(u, v)\}$  функции заданы в пространственной области. Локальная энергия  $E(x, y)$ , локальная ориентация  $\theta_{or}(x, y)$  и локальная фаза  $\phi(x, y)$  могут быть вычислены следующим образом [20], [21]:

$$E(x, y) = \sqrt{(f_p(x, y))^2 + (f_x(x, y))^2 + (f_y(x, y))^2}, \quad (11)$$

$$\theta_{or}(x, y) = \arctan\left(\frac{f_y(x, y)}{f_x(x, y)}\right), \quad (12)$$

$$\varphi(x, y) = \arctan\left(\frac{\sqrt{(f_x(x, y))^2 + (f_y(x, y))^2}}{f_p(x, y)}\right). \quad (13)$$

Робастный вариант фазовой конгруэнтности можно определить как [16]


$$PC(x) = \max_{\varphi(x) \in [0, 2\pi]} \frac{\sum_n W(x) [A_n \cos(\varphi_n(x) - \bar{\varphi}(x)) - T]}{\sum_n A_n + \varepsilon}, \quad (14)$$

где  $W(x)$  — весовая функция,  $E(x)$  — энергия сигнала,  $T$  — порог, зависящий от шума,  $\varepsilon$  — малая константа для исключения деления на ноль. Значение весовой функции указывает на значимость данного признака: единица означает наиболее значимый признак, а ноль указывает на самую низкую значимость. Эти локальные признаки будут использованы на следующих этапах обработки. На Рис. 2 показано выделение фазовых признаков на изображениях маммограмм, взятых из четырех открытых баз данных: а) MIAS [20]; б) CBIS-DDMS [21]; в) CSAW-M [22]; г) InBreast [23].

Для наших экспериментов мы сравниваем несколько архитектур сверточных нейронных сетей (CNN), включая VGG16 [24], InceptionV2 [25], Xception [26], ResNet50 [27], DenseNet169 [28] и Inception-Resnet-V2 [29]. Для наших экспериментов последние полносвязные слои сетей были заменены двумя полносвязными слоями из 64 и 32 узлов с функцией активации ReLU и конечным выходным слоем из двух узлов с функцией активации softmax. Для этапа обучения были реализованы тонкая настройка и увеличение изображения. Тонкая настройка проводилась путем заморозки большинства сверточных слоев и сохранения без изменения трех последних сверточных слоев и добавленных полносвязных слоев сети. Чтобы предотвратить переобучение, было реализовано увеличение данных посредством таких преобразований как поворот (10 градусов), горизонтальное и вертикальное отражение, сдвиг (25%) и масштабирование (10%). Функция кросс-энтропийных потерь и модель оптимизации Адама [30] со скоростью обучения 0,0001 использовались для обучения сети в течение 20 эпох. Все архитектуры были реализованы на Python с использованием библиотеки Keras [31].

## 2. КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

Для оценки эффективности классификации аномалий молочной железы с использованием фазовых признаков использовались следующие базы данных: MIAS [20], CBIS-DDMS [21], CSAW-M [22] и InBreast [23]. База данных MIAS состоит из 328 маммографических изображений (1024 × 1024 пикселей), разделенных на три основные категории: нормальные, доброкачественные, злокачественные образования и семь типов аномалий, таких как асимметрия,



**Рис. 2.** Исходные изображения (слева) и локальная информация о фазе изображения (справа) для четырех маммограмм, взятых из открытых баз данных: а) MIAS [20]; б) CBIS-DDSM [21]; в) CSAW-M [22]; г) InBreast [23].

нарушение архитектоники, кальцификация и т.д. В наших экспериментах мы не использовали изображения с кальцификацией. База данных CBIS-DDSM содержит 2620 отсканированных маммографических исследований на пленке ( $2672 \times 4720$  пикселей), разделенных на три основные категории: нормальные, доброкачественные и злокачественные образования. База данных CSAW-M является крупнейшим общедоступным набором маммографических данных. Она содержит 10020 цифровых маммографических изображений ( $632 \times 512$  пикселей), разделенных на доброкачественные и злокачественные классы и сгруппированные в восемь уровней маскировки. База данных InBreast имеет 410 цифровых маммографических изображений ( $3328 \times 4084$  пикселей), содержащих несколько признаков: асимметрии, кальцификации, искажения, различные образования, сгруппированные в нормальные, доброкачественные и злокачественные классы. Так как результирующий набор данных был несбалансированным (11536 доброкачественных и 2088 злокачественных случаев), то были рассчитаны веса классов (доброкачественные: 0.5905, злокачественные: 3.2612).

Чтобы повысить надежность результатов, мы провели 5-кратную перекрестную проверку при этом были использованы следующие критерии эффективности [32]: точность (ACC), сбалансированная точность (BAL-ACC) и площадь под кривой ROC (AUC-ROC). Экспериментальные результаты приведены далее. На Рис.3 показаны примеры маммограмм из используемых баз данных, а в Таблице 1 приведены полученные результаты классификации.

**Таблица 1.** Результаты классификации доброкачественных и злокачественных образований.

Network	ACC	BAL-ACC	AUC-ROC
VGG16	81.2%	72.0%	76.9%
ResNet50	<b>85.2%</b>	69.3%	78.7%
InceptionV2	80.6%	71.8%	75.7%
Inception-ResNet-V2	81.2%	73.2%	<b>79.0%</b>
DenseNet169	83.6%	<b>75.4%</b>	76.7%
Xception	79.5%	72.5%	76.5%

Тестируемые модели достигли похожих результатов по точности (ACC) до 85%, сбалансированной точностью (BAL-ACC) до 75% и AUC-ROC до 79%. Как мы и ожидали, сбалансированная точность упала по сравнению с метрикой точности из-за дисбаланса между классами. Тем не менее, хотя архитектура ResNet50 достигла наилучшей точности, около 85,2%, ее сбалансированная точность упала до 69,3%. Модели Inception-ResNet-V2 и DenseNet169 получили наиболее сбалансированные значения точности и AUC-ROC, до 79% и 76%, соответственно. Мы считаем, что увеличение количества изображений неосновного класса (злокачественные образования) значительно улучшит качество работы моделей; в частности, сетей Inception-ResNet-V2 и DenseNet169.




Рис. 3. Примеры маммограмм из каждой используемой базы данных.

### 3. ЗАКЛЮЧЕНИЕ

В данной работе представлен сравнительный анализ нескольких свёрточных нейронных сетей для классификации аномалий молочной железы. Сравниваются несколько моделей глубокого обучения для классификации доброкачественных и злокачественных образований на цифровых маммограммах. Представлен метод классификации аномалий молочной железы с

использованием моногенного сигнала, фазовой конгруэнтности и нескольких архитектур сверточных нейронных сетей. На этапе предварительной обработки было произведено удаление шума, изменение размера изображений и извлечение информации о локальной фазе изображения в качестве признака. Эксперименты дали многообещающие результаты, учитывая сложность различения и дисбаланс между двумя классами. В качестве будущей работы будут исследованы методы настройки гиперпараметров и несбалансированных классов для улучшения полученных результатов.

Благодарность. Исследование частично поддержано грантом Российского научного фонда (проект № 22-19-20071).

#### СПИСОК ЛИТЕРАТУРЫ

1. <https://www.cancer.net/cancer-types/breast-cancer/statistics>
2. Weigel S., Heindel W., Dietz C., Meyer-Johann U., Graewingholt A., Hense H. W. Stratification of breast cancer risk in terms of the influence of age and mammographic density // in [RoFo-Fortschritte auf dem Gebiet der Rontgenstrahlen und der bildgebenden Verfahren], 2020, vol. 192(07), pp. 678–685, ©Georg Thieme Verlag KG.
3. Andrew D. Trister, Diana S. M. Buist, Christoph I. Lee. Will machine learning tip the balance in breast cancer screening? JAMA oncology, 2017, vol. 3(11), pp. 1463–1464.
4. Методические рекомендации по использованию системы BI-RADS при маммографическом обследовании. Под ред. А. Ю. Васильева. Москва. 23с., 2017.
5. D’Orsi C.J., Sickles E.A., Mendelson E.B., Morris E.A. et al. ACR BI-RADS® Atlas, Breast Imaging Reporting and Data System. Fifth Edition. Reston VA, American College of Radiology; 1–79, 2013.
6. American College of Radiology. ACR Breast Imaging Reporting and Data System (BI-RADS) Website, [www.acr.org](http://www.acr.org).
7. Hassan N. M., Hamad S., and Mahar K. Mammogram breast cancer cad systems for mass detection and classification: a review // Multimedia Tools and Applications, 2022, pp. 1–33.
8. Meenalochini G. and Ramkumar S. Survey of machine learning algorithms for breast cancer detection using mammogram images // Materials Today: Proceedings, 2021, vol. 37, pp. 2738–2743.
9. P. Gomina, V. Kober, V. Karnaukhov, M. Mozerov, A. Kober. Classification of breast abnormalities using deep learning // Journal of Communications Technology and Electronics, 2022, Vol. 67, No. 12, pp. 1552–1556.
10. A.N. Ruchay, V.I. Kober, K.A. Dorofeev, V.N. Karnaukhov, M.G. Mozerov. Segmentation of breast masses in digital mammography based on a deep convolutional neural network U-net // Journal of Communications Technology and Electronics, 2022, Vol. 67, No. 12, pp. 1531–154.
11. Ruchai A., Kober V., Dorofeev K., Karnaukhov V., Mozerov M. Classification of breast abnormalities using a deep convolutional neural network and transfer learning. Journal of Communications Technology and Electronics, 2021, vol. 66(6), pp. 778–783.
12. Diaz-Escobar J., Kober V., Karnaukhov V., Mozerov M. Recognition of breast abnormalities using phase features. Journal of Communications Technology and Electronics, 2020, vol. 65(12), pp. 1476–1483.
13. Destounis, S., Johnston, L., Highnam, R., Arieno, A., Morgan, R., and Chan, A. Using volumetric breast density to quantify the potential masking risk of mammographic density // AJR Am J Roentgenol, 2017, vol. 208(1), 222–227.
14. F. Attneave. Some informational aspects of visual perception. Psychological review, 61(3):183, 1954.
15. M Concetta Morrone and DC Burr. Feature detection in human vision: A phase-dependent energy model. Proceedings of the Royal Society of London B: Biological Sciences, 235(1280):221–245, 1988.



16. Ben Robbins and Robyn Owens. 2d feature detection via local energy. *Image and Vision Computing*, 15(5):353–368, 1997.
17. Peter Kovesi. Image features from phase congruency. *Videre: Journal of computer vision research*, 1(3):1–26, 1999.
18. Michael Felsberg and Gerald Sommer. The monogenic signal. *IEEE Transactions on Signal Processing*, 49(12):3136–3144, 2001.
19. Michael Felsberg and Gerald Sommer. The monogenic scale-space: A unifying approach to phase-based image processing in scale-space. *Journal of Mathematical Imaging and vision*, 21(1):5–26, 2004.
20. John Suckling, et al. The mammographic image analysis society digital mammogram database // *Digital Mammo*, 375–386 (1994).
21. Heath, M., Bowyer, K., Kopans, D., Kegelmeyer, P., Moore, R., Chang, K., and Munishkumaran, S. Current status of the digital database for screening mammography // in [Digital mammography], 457–460, Springer (1998).
22. Sorkhei M., Liu Y., Azizpour H. et al. CSAW-M: An Ordinal Classification Dataset for Benchmarking Mammographic Masking of Cancer. arXiv:2112.01330v1, 2021.
23. Moreira, I. C., Amaral, I., Domingues, I., Cardoso, A., Cardoso, M. J., and Cardoso, J. S., Inbreast: toward a full-field digital mammographic database // *Academic radiology* 19(2), 236–248 (2012).
24. Simonyan, K. and Zisserman, A. Very deep convolutional networks for large-scale image recognition // arXiv preprint arXiv:1409.1556 (2014).
25. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. Going deeper with convolutions. *IEEE Computer Vision and Pattern Recognition*, 2015. <http://arxiv.org/abs/1409.4842>.
26. Chollet, F. Xception: Deep learning with depthwise separable convolutions // in [Proceedings of the IEEE conference on computer vision and pattern recognition ], 1251–1258 (2017).
27. He K., Zhang X., Ren S., Sun, J. Deep residual learning for image recognition. Tech. report, 2015. <http://arxiv.org/abs/1512.03385>.
28. Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. Densely connected convolutional networks // in [Proceedings of the IEEE conference on computer vision and pattern recognition ], 4700–4708 (2017).
29. He, K., Zhang, X., Ren, S., and Sun, J. Identity mappings in deep residual networks // in [European conference on computer vision ], 630–645, Springer (2016).
30. Kingma, D. P. and Ba, J. Adam: A method for stochastic optimization // arXiv preprint arXiv:1412.6980 (2014).
31. Chollet, F. Keras. GitHub <https://github.com/keras-team/keras> (2015).
32. Japkowicz, N. and Shah, M. Evaluating learning algorithms: a classification perspective. Cambridge University Press (2011).

## Comparative Analysis of Convolutional Neural Networks for Classification of Breast Abnormalities

**Julia Diaz-Escobar, Vitaly Kober, Victor Karnaukhov, and Michael Mozerov**

Computer Aided Detection (CAD) systems are used by radiologists as a second interpreter for breast cancer detection in digital mammography. However, for every true positive cancer detected by the CAD system, a large number of false predictions must be reviewed by the expert to avoid an unnecessary biopsy. The traditional approach to creating such systems is to select and compute the features of objects of interest from the source data, followed by the selection of a model for their classification using machine learning.

Machine learning and especially deep learning are being used to analyze mammograms. Most of the models proposed so far are trained on a small amount of data and do not have high reliability. This paper compares several deep learning models for benign-malign mammography classification on digital mammograms. The pre-processing step is designed to remove noise and extract features using local phase information of the image. Machine learning is then used to classify the digital mammography. Experimental results are presented using several databases and evaluated using several quality criteria.

**KEYWORDS:** mammography, breast cancer, Computer Aided Detection, phase features, machine learning, neural networks.