

## Распознавание аномалий молочной железы с использованием фазовых признаков

**Х. Диаз-Эскобар\***, **В.И. Кобер\*\***, **В.Н. Карнаузов\*\***, **М.Г. Мозеров\*\***

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

*\*\* Институт проблем передачи информации, Российская академия наук, Москва, 127051, Россия*

Поступила в редколлегию 01.06.2020

**Аннотация**—Раннее выявление патологий молочной железы и правильное лечение увеличивают вероятность излечения, и, как следствие, продолжительность жизни женщин. В настоящее время активно разрабатываются методы и алгоритмы для систем компьютерной диагностики. 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 методов машинного обучения. В этой работе предлагается метод обнаружения и классификации аномалий молочной железы, основанный на локальной энергетической и фазовой конгруэнтности и управляемом классификаторе машинного обучения. Экспериментальные результаты представлены с использованием базы данных цифровой маммографии и оценены с использованием различных критериев качества.

**КЛЮЧЕВЫЕ СЛОВА:** рак молочной железы, система компьютерной диагностики (СКД), фазовые признаки, моногенный сигнал.

### ВВЕДЕНИЕ

Рак молочной железы (РМЖ) является наиболее распространенным видом рака и одной из основных причин смерти среди женщин во всем мире [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. 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 медиалатеральные (MLO) и левая/правая краниокаудальные (CC) [2]. Стандартное описание маммограмм [3] включает в себя следующую информацию: показание к проведению обследования (скрининг; диагностическое исследование; контрольное наблюдение); описание структуры молочных желёз 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 [4] – система интерпретации и протоколирования визуализации молочной железы. Основной целью создания системы BIRADS была разработка унифицированного языка/терминов интерпретации результатов осмотра молочных желёз, 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 [5]. Образования округлой и овальной формы с гладкими краями обычно указывают на доброкачественные изменения, а вот резкие и неровные границы указывают на злокачественное образование.

Как правило, рентгенологические изображения нелегко интерпретировать. Так визуальная диагностика РМЖ по рентгеновским маммограммам имеет ложно-отрицательный (пропущенный рак) уровень более 16%, что связано с плотной тканью молочной железы, скрывающей рак, со зрительными ограничениями человека и с наличием шума на изображениях [6]. 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). Традиционный подход к созданию таких систем состоит из выбора и расчета признаков интересующих объектов из исходных данных с последующим подбором модели для их классификации. По сути, типичная СКД состоит из следующих последовательных этапов [7]: (а) этап предварительной обработки, который используется для улучшения качества изображения, удаления шума и устранения меток на изображении маммограммы; (б) этап сегментации областей интереса, который используется для извлечения областей, содержащих патологии; (в) извлечение различных текстурных, статистических и геометрических признаков; (г) этап классификации, где ранее обученный классификатор используется для выявления и классификации патологий в тканях молочной железы. Так в работе [8] предложена система для диагностики рака молочной железы, основанная на вейвлет-преобразовании для получения признаков в области интереса. В целях уменьшения размера описания признаков использовался гибридный подход к выбору признаков, в котором генетический алгоритм и машина опорных векторов объединены, чтобы обнаружить и классифицировать патологии. Отметим, что в современных системах компьютерной диагностики используются в основном линейные методы обработки [9, 10]. Так методы главных и независимых компонент являются лишь способами понижения размерности пространства признаков, вейвлет-преобразования - интегральные преобразования, смесь гауссовских распределений состоит из ограниченного количества гауссовских функций.

В этой работе предлагается метод обнаружения и классификации объемных образований молочной железы для системы СКД. Предлагаемый метод основан на модели локальной энергетической и фазовой конгруэнтности и управляемом классификаторе машинного обучения. Экспериментальные результаты представлены с использованием известной базы данных по цифровой маммографии. Статья организована следующим образом: в разделе 1 описан предлагаемый подход к построению СКД, в разделе 2 представлены и обсуждены полученные результаты экспериментов с помощью компьютерного моделирования, и раздел 3 суммирует наши выводы.

## 1. ОБНАРУЖЕНИЕ И КЛАССИФИКАЦИЯ АНОМАЛИЙ МОЛОЧНОЙ ЖЕЛЕЗЫ

Обнаружение областей интереса, которые могут содержать подозрительные образования молочной железы, производится с помощью информации о локальной фазе изображения. Выделенные области фильтруются с учетом геометрических свойств образований, а оставшиеся области рассматриваются как кандидаты для последующей классификации с помощью классификатора AdaBoost на нормальные и аномальные образования. На первом этапе устраняются шум и метки, улучшается качество изображения [11, 12, 13]. Однако применение методов улучшения изображения может привести к потере важной информации. Поэтому для удаления меток на маммографических изображениях используется пороговая обработка, как показано на Рис. 1. После удаления меток на изображениях производится обнаружение и извлечение образований молочной железы с использованием моногенного сигнала. В работе [14] предло-

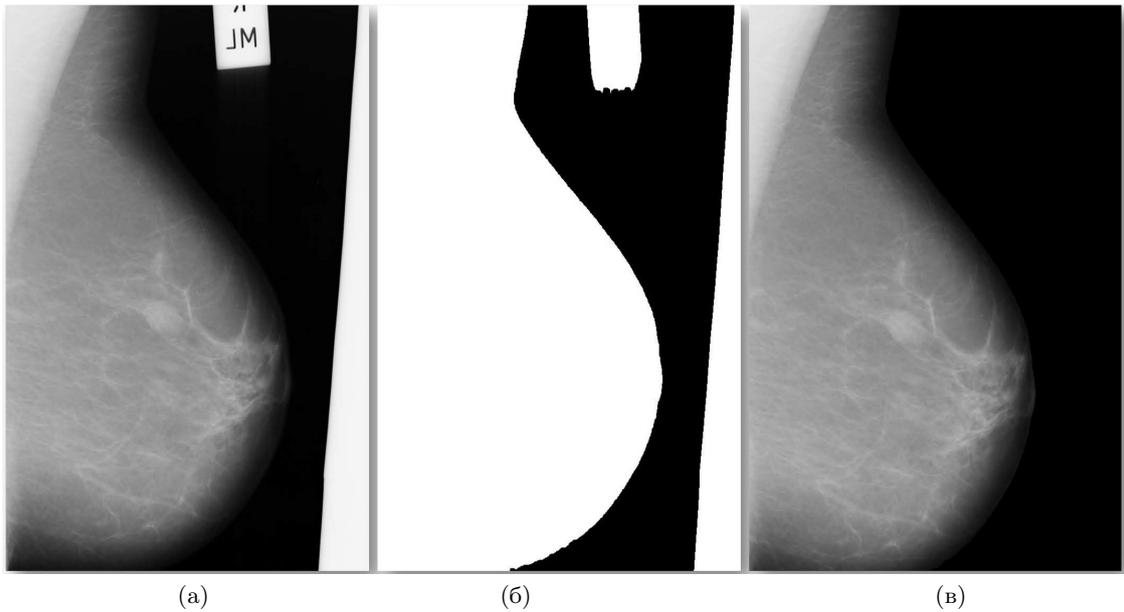


Рис. 1. Предварительная обработка: (а) исходное изображение; (б) пороговая обработка; (в) удаление метки.

жена 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, называемого моногенный сигнал.

Пусть  $H_e \in L^2$  и  $H_o \in L^2$  – 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 информацию 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  $A_n$  – амплитуды  $n$ -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 задается 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  $\mathbf{R} = (R_x, R_y)$ . 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 полосовой 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  $k \in N$  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  $\varphi(x, y)$  могут быть вычислены следующим образом [20, 21]:

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

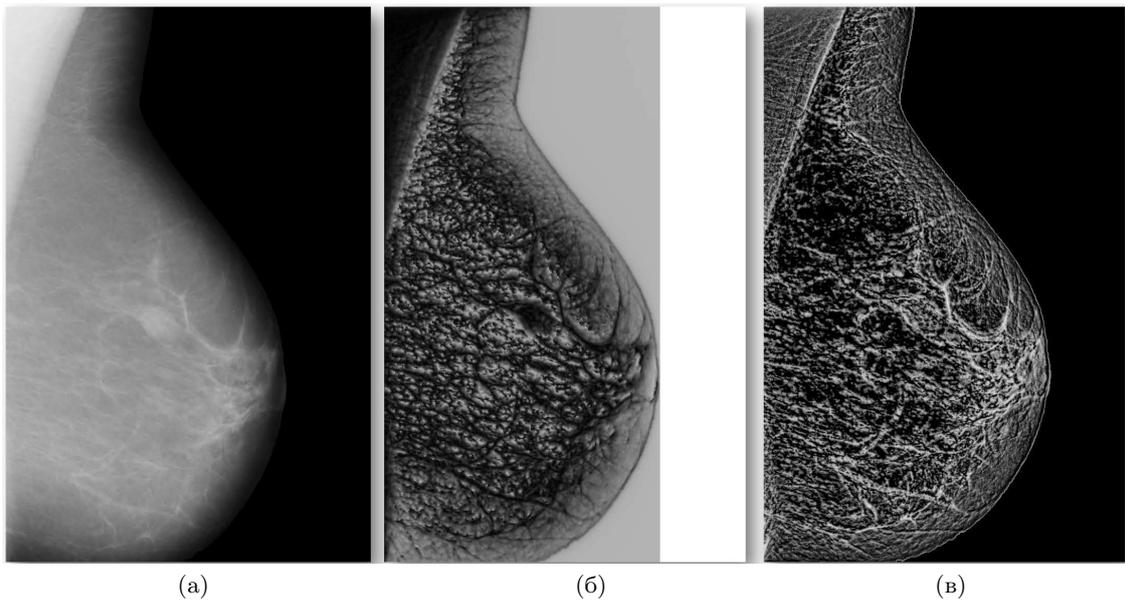
$$\theta_{or}(x, y) = \arctan\left(\frac{f_y(x, y)}{f_x(x, y)}\right), \quad (12)$$

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

Робастный вариант фазовой конгруэнтности можно определить как [16]

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

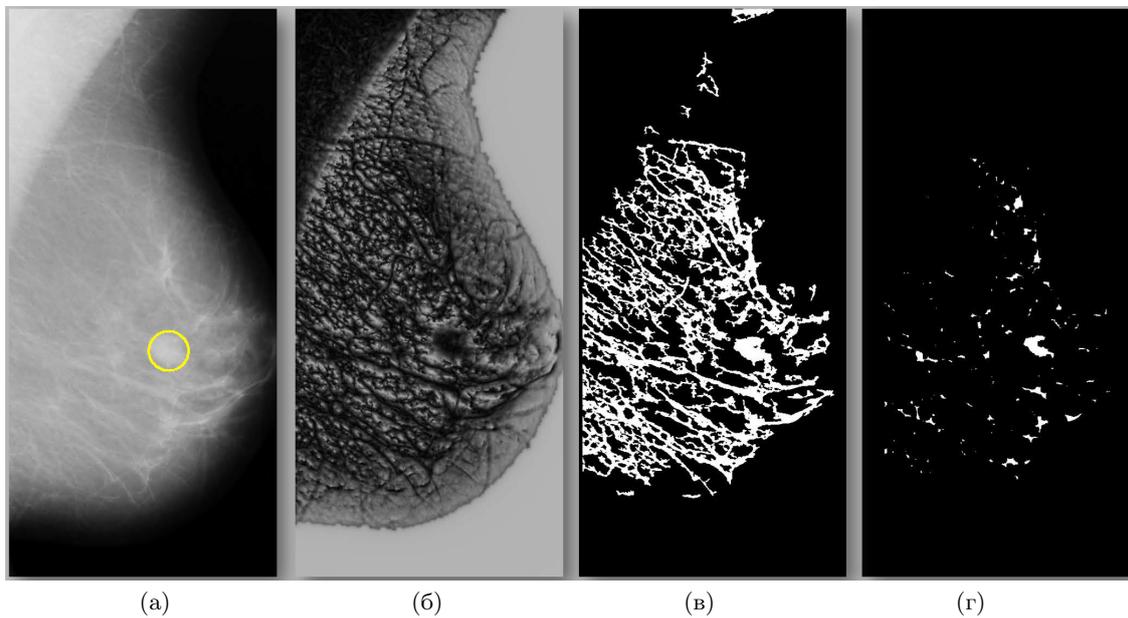
где  $W(x)$  – весовая функция,  $E(x)$  – энергия сигнала,  $T$  – порог, зависящий от шума,  $\varepsilon$  – малая константа для исключения деления на ноль. Значение  $PC(x)$  указывает на значимость данного признака: единица означает наиболее значимый признак, а ноль указывает на самую низкую значимость. Эти локальные признаки будут использованы на следующих этапах обработки. На Рис. 2 показано выделение фазовых признаков на изображении маммограммы.



**Рис. 2.** Информация о фазе изображения: (а) изображение; (б) локальная фаза; (в) конгруэнтность локальной фазы.

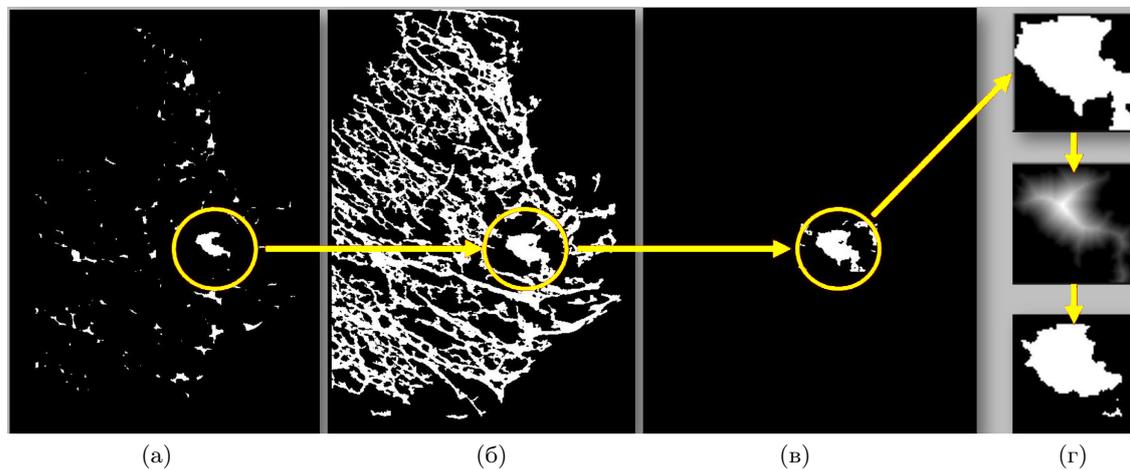
Следующим этапом обработки будет фазовая сегментация для выделения областей интереса, содержащих патологии. Локально-фазовое изображение содержит структурную информацию, по нему можно различить виды границ областей и линий [22]. Поэтому изображение

локальной фазы будет использоваться для выделения подозрительных структур молочной железы. Сначала к изображению локальной фазы применяется пороговая обработка [23]. Для выделения только крупных структур выполняется морфологическая операция эрозии (Рис. 3). Наконец, из изображений после морфологической и пороговой обработок (см. Рис. 4(а) и



**Рис. 3.** Выделение области интереса: (а) изображение; (б) локальная фаза; (в) пороговое обработка; (г) морфологическая обработка.

Рис. 4(б)) выбирается область интереса (см. Рис. 4(в)) и выполняется сегментация (Рис. 4(г)). Следующим этапом обработки является извлечение признаков и классификация областей ин-



**Рис. 4.** Сегментация области интереса: (а) морфологическая обработка; (б) пороговая обработка; (в) выбранная область интереса; (г) сегментация области интереса.

тереса. Для классификации использовались структурные и статистические признаки, которые приведены в Таблице 1. Здесь используются следующие обозначения:  $ROI_{minRect}$  – минималь-

ный прямоугольник, который охватывает область интереса,  $area(.)$  – площадь,  $len(.)$  – длина,  $mean(.)$  – среднее значение,  $var(.)$  – дисперсия,  $E(.)$  – математическое ожидание,  $StdDev(.)$  – среднеквадратичное отклонение,  $ROI_{con}$  – контур области интереса,  $ROI_{stroke}$  – ширина области (расстояние между двумя краями области, измеренное перпендикулярно центральной линии области) [23, 24], а  $PC(.)$  – средняя конгруэнтность фазы. Чтобы исключить области с ложной структурой, сегментированные области фильтруются по соотношению сторон, площади и фазовой конгруэнтности. Затем, оставшиеся сегментированные области классифицируются на нормальные и аномальные с помощью ранее обученного классификатора AdaBoost.

## 2. КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

Для оценки эффективности предложенного метода использовалась база данных MIAS [25]. Эта база данных состоит из 328 маммографических изображений (1024x1024 пикселей), разделенных на три основные категории: нормальные, доброкачественные, злокачественные образования и семь типов аномалий, таких как асимметрия, нарушение архитектоники, кальцификация и т.д. В наших экспериментах мы не использовали изображения с кальцификацией. Для оценки эффективности предложенного подхода были использованы следующие критерии: точность, чувствительность и специфичность. Эти метрики определяются следующим образом [8]:

$$accuracy = \frac{TP + TN}{TN + FP + FN + TP}, \quad (15)$$

$$specificity = \frac{TN}{TN + FP}, \quad (16)$$

$$sensitivity = \frac{TP}{FN + TP}, \quad (17)$$

где  $TN$  – истинно-отрицательный,  $FP$  – ложно-положительный,  $FN$  – ложно-отрицательный и  $TP$  – истинно-положительный результаты экспериментов.

Экспериментальные результаты приведены далее. Во-первых, для оценки качества сегментации использовались только изображения MIAS с наличием аномалий (кальцификация была исключена). В результате, 90,4% патологий были правильно сегментированы. Некоторые области были интерпретированы как неправильно сегментированные из-за их отличия от вариантов сегментирования, приведенных вместе с базой данных. Кроме того, предварительно определенный порог для извлечения областей интереса также приводит к ошибкам сегментации. Однако, последнюю ошибку сегментации можно исправить, используя пороговое разложение изображения локальной фазы. Для классификации норма – аномалия было отобрано 120 изображений. Выбранные изображения были разделены на 70 обучающих изображений и 50 тестовых изображений. В Таблице 2 приведены полученные результаты классификации.

С помощью предложенного метода обнаружения и классификации было получено 9 ложно-положительных и только 3 ложно-отрицательных срабатываний. Важным результатом является низкое число ложно-отрицательных срабатываний, то есть когда злокачественные образования классифицируются как доброкачественные. Ложно-положительные срабатывания могут быть отброшены на следующем этапе обработки, а вот ложно-отрицательные срабатывания уже нельзя откорректировать. На Рис. 5 приведены примеры правильной работы предлагаемого метода.

Таблица 1. Выбранные признаки для классификатора.

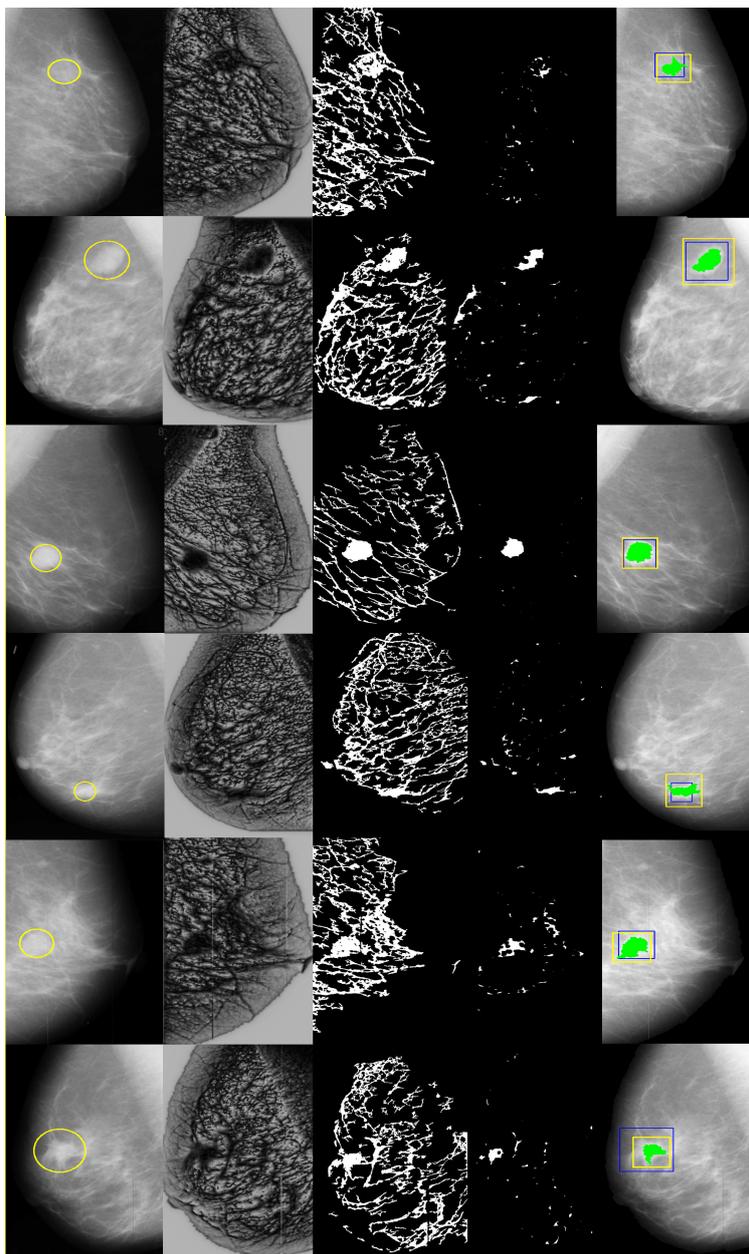
Признак	Определение
Area	$\frac{area(ROI)}{area(Image)}$
Occupy	$\frac{area(ROI)}{area(ROI_{min\ Rect})}$
Eccentricity	$\sqrt{1 - \left(\frac{len(ROI_{min\ Area})}{len(ROI_{max\ Area})}\right)^2}$
Solidity	$\frac{area(ROI)}{area(ROI_{ConHull})}$
Compactness	$\frac{ROI_{area}}{len(ROI_{con})^2}$
Aspect ratio	$\frac{\min(ROI_{width}, ROI_{height})}{\max(ROI_{width}, ROI_{height})}$
Skel-contour ratio	$\frac{len(ROI_{skel})}{len(RR_{con})}$
Stroke width value	$\frac{var(ROI_{stroke})}{E(ROI_{stroke})^2}$
Mean	$\frac{mean(ROI)}{255}$
Mean ratio	$\frac{mean(ROI)}{mean(ROI^c)}$
Standard deviation	$\frac{stdDev(ROI)}{255}$
Phase congruency	$mean(PC(ROI_{con}))$

Таблица 2. Классификации образований молочной железы на нормальные и аномальные.

Accuracy	Specificity	Sensitivity
89.3%	89.0%	90.2%

## ЗАКЛЮЧЕНИЕ

В данной работе предложен метод обнаружения и классификации аномалий молочной железы с использованием моногенного сигнала, фазовой конгруэнтности и контролируемом классификаторе машинного обучения. Полученные экспериментальные результаты показывают, что предложенная сегментация позволяет выделить большинство аномальных образований на изображении маммограммы (до 89%). Мы считаем, что техника сегментации играет важную роль в классификации областей интереса. Следовательно, метод сегментации может быть улучшен, используя пороговое разложение изображения локальной фазы. Кроме того, важным результатом применения предложенного метода является низкое число ложно-отрицательных срабатываний.



**Рис. 5.** Примеры правильной классификации аномалий: темный прямоугольник – сегментированная область из базы данных, светлый прямоугольник – полученная область.

#### СПИСОК ЛИТЕРАТУРЫ

1. Freddie Bray, Jacques Ferlay, Isabelle Soerjomataram, Rebecca L. Siegel, Lindsey A. Torre, Ahmedin Jemal. Global cancer statistics 2018: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*, 68(6), 394–424, 2018.
2. Методические рекомендации по использованию системы BI-RADS при маммографическом обследовании. Под ред. А. Ю. Васильева. Москва. 23с., 2017.
3. 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.

4. American College of Radiology. ACR Breast Imaging Reporting and Data System (BI-RADS) Website, [www.acr.org](http://www.acr.org).
5. Jelena Bozek, Mario Mustra, Kresimir Delac, Mislav Grgic. A survey of image processing algorithms in digital mammography, *Recent advances in multimedia signal processing and communications*, 631–657, Springer, 2009.
6. Andrew D. Trister, Diana S. M. Buist, Christoph I. Lee. Will machine learning tip the balance in breast cancer screening? *JAMA oncology*, 3(11) 1463–1464, 2017.
7. Luqman Mahmood Mina and Nor Ashidi Mat Isa. A review of computer-aided detection and diagnosis of breast cancer in digital mammography. *Journal of Medical Sciences*, 15(3): 110, 2015.
8. Mohamed S. Salama, Ahmed S. Eltrass, Hassan M. Elkamouchi. An improved approach for computer-aided diagnosis of breast cancer in digital mammography. in *IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, 1–5, IEEE, 2018.
9. Doi K., Computer-aided diagnosis in medical imaging: historical review, current status and future potential, *Comput Med Imaging Graph* 31 (4), 198–211 (2017).
10. Halalli D., Makandar A., Computer Aided Diagnosis - Medical Image Analysis Techniques, Breast Imaging, C. M. Kuzmiak (Ed.), *IntechOpen (January 17th 2018)*, 10.5772/intechopen.69792.
11. Robust and efficient algorithm of image enhancement. *IEEE Transactions on Consumer Electronics*, 52(2): 655–659, 2006.
12. Vitaly Kober, Michael Mozerov, Jusue Alvarez-Borrego. Nonlinear filters with spatially-connected neighborhoods. *Optical Engineering*, 40(6): 971–983, 2001..
13. Vitaly Kober, Michael Mozerov, Jusue Alvarez-Borrego, and Iosif A. Ovseyevich. Fast algorithms of rank-order filters with spatially adaptive neighborhoods. *Pattern recognition and image analysis*, 11(4): 690–698, 2001.
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 Kovesei. 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. Julia Diaz-Escobar, Vitaly Kober, Victor Karnaukhov, Jose Gonzalez-Fraga. A new invariant to illumination feature descriptor for pattern recognition. *Journal of Communications Technology and Electronics*, 63(12): 1469–1474, 2018.
21. Julia Diaz-Escobar, Vitaly Kober, Jose Gonzalez-Fraga. Luift: Lumination invariant feature transform. *Mathematical Problems in Engineering*, 2018.
22. Peter Kovesei et al. Edges are not just steps. *Proceedings of the Fifth Asian Conference on Computer Vision*, Vol. 8, pages 22–8. Melbourne, 2002.
23. Julia Diaz-Escobar and Vitaly Kober. Text detection in natural scenes with phase congruency approach. *SPIE Optical Engineering Applications*, 10396: 1039637, International Society for Optics and Photonics, 2017.
24. Yao Li, Wenjing Jia, Chunhua Shen, Anton van den Hengel. Characterness: An indicator of text in the wild. *IEEE transactions on image processing* 23(4): 1666–1677, 2014.

25. John Suckling, et al. The mammographic image analysis society digital mammogram database. *Mammographic Image Analysis Society (MIAS) database v1.21* [Dataset], 2015. <https://www.repository.cam.ac.uk/handle/1810/250394>

## Recognition of breast abnormalities using phase features

**Diaz-Escobar J., Kober V., Karnaukhov V., Mozerov M.**

Early detection of breast pathologies and proper treatment increase the likelihood of cure, and, as a result, life expectancy. Currently, methods and algorithms for Computer Aided Detection (CAD) systems are being actively developed. The traditional approach to the design of such systems consists in the selection and calculation of features of region of interest from the source data, followed by the selection of a model for their classification using machine learning methods. This paper proposes a method for detecting and classifying breast anomalies based on local energy and phase congruency and a controlled machine learning classifier. Experimental results are presented using a digital mammography dataset and evaluated using various performance criteria.

**KEYWORDS:** Breast cancer, Computer Aided Detection (CAD), phase features, monogenic signal.