# Распознавание образов

# Оценка обобщающей способности алгоритма вложенных контуров при анализе маммограмм\*

И.А. Егошин

Федеральное государственное бюджетное образовательное учреждение высшего профессионального образования «Марийский государственный университет», г. Йошкар-Ола, Россия

Аннотация. В работе представлен алгоритм вложенных контуров, предназначенный для обнаружения патологических изменений, которые могут соответствовать раку молочной железы, на рентгеновских маммографических изображениях. Приведены результаты оценки его обобщающей способности. Данный алгоритм был протестирован на обширной выборке маммографических изображений всех возможных вариантов изменений, соответствующих верифицированному раку молочной железы, включая нечетко видимые и невидимые. Общая точность обнаружения алгоритма составила 90,73% – для пленочных и 96,82% – для цифровых маммограмм. Приведен сравнительный анализ использования данного алгоритма и других современных методик обнаружения изменений на маммограммах с использованием общедоступных баз данных (INbreast и CBIS-DDSM). Показана более высокая точность предложенного алгоритма. Высокая эффективность обнаружения патологических изменений, вне зависимости от различия характеристик маммограмм, полученных на разных системах, свидетельствует о высокой обобщающей способности предложенного алгоритма.

Ключевые слова: рак молочной железы, маммография, обнаружение, линии уровня, обобщающая способность.

DOI: 10.14357/20790279240308 EDN: NXRKLK

# Введение

Рак молочной железы (РМЖ) – это онкологическое заболевание, являющееся главной причиной смерти у женщин [1], поэтому актуальными являются любые подходы к раннему его выявлению, основным из которых на сегодняшний день является маммография [2]. Однако маммографические изображения характеризуются очень большой вариабельностью характеристик как фона, так и патологических изменений, которые могут

Труды ИСА РАН. Том 74. 3/2024

соответствовать РМЖ. Достаточно часто РМЖ визуально не определяется на интенсивном фоне, что является основной причиной пропуска данной патологии, особенно на ранней стадии, врачами-рентгенологами [3].

Существуют различные автоматические системы медицинской диагностики, позволяющие обнаруживать широкий круг патологических изменений, применение которых в клинической практике перспективно для первичной обработки маммографических изображений [4].

Методы цифровой обработки изображений, реализованные в данных системах, можно разделить на три группы: методы, основанные на ис-

<sup>\*</sup> Основные результаты разделов «Материалы и методы» и «Результаты» получены И.А. Егошиным при поддержке гранта Российского научного фонда № 24-21-00031, https://rscf.ru/ project/24-21-00031/

пользовании адаптивного порога [5], методы, основанные на анализе окружающих областей [6] и модели глубокого обучения [7,8].

Однако все они имеют ряд недостатков при анализе маммограмических изображений. Например, широкая вариабельность как размеров патологических изменений. так и их пространственной локализации, затрудняет выбор размера окна обработки для расчета адаптивного порога. Результат использования методов, основанных на анализе окружающих областей, может быть неустойчив, когда текстурные признаки нормальных структур и тканей молочной железы (МЖ) схожи с таковыми патологического очага, что достаточно характерно для маммограмм. Сети глубокого обучения на сегодняшний день оказались одним из перспективных способов сегментации изображений из-за способности автоматически извлекать признаки изображения и обрабатывать сложные данные. Однако к их недостаткам можно отнести то, что результат прогнозирования может быть недостаточно устойчив из-за уровня обобщения модели, когда невозможно обобщать новые ситуации или контексты, которые не были представлены в данных, использовавшихся для обучения.

Кроме того, важной проблемой использования рассмотренных методов цифровой обработки для анализа маммографических изображений и внедрения их в различные компьютерные системы компьютерной диагностики РМЖ является то, что характеристики самих маммограмм также зависят от аппаратуры, на которой производится их получение, и могут варьироваться в широких пределах. Данная особенность требует дополнительной адаптивности (обобщаемости) при внедрении подобных методов в клиническую практику.

Ранее нами был разработан алгоритм вложенных контуров (ABK), который продемонстрировал хорошие результаты при идентификации широкого круга изменений, соответствующих РМЖ, в том числе плохо видимых и невидимых при визуальном их анализе [9]. Поэтому целью работы было оценить его обобщающую способность при обработке маммографических изображений, полученных из разных источников и имеющих разные характеристики.

# 1. Материалы и методы

Материалы. При выполнении маммографии стандартом является получение двух изображений каждой МЖ (соответственно, четырех — на пациентку), позволяющих отобразить различные отделы МЖ, поскольку полный охват всего объема паренхимы МЖ при получении только одного изображения невозможен. Для разработки и оценки эффективности алгоритма обнаружения изменений МЖ использовался собственный набор из 356 пленочных и 252 цифровых маммограмм (всего 608 маммограмм), полученных только из частной базы данных (публичные базы данных при разработке не использовались). Присутствующие типы изменений МЖ представлены в табл. 1.

# Табл. 1

Рассмотренные типы из	менений МЖ
-----------------------	------------

Тип изменения	Количество случаев
Звездчатые образования	322
Спикулизированные с небольшим и плотным центром и длинными спикулами	14
Изменения неправильной формы с нечеткими контурами	58
Дольчатые и круглые с полностью или частично четкими контурами	60
Частично визуализируемые	22
Асимметрия плотности	46
Нечетко видимые или невидимые	16
Изменение структуры паренхимы	8
Не визуализирующиеся образования на фоне плотной паренхимы	38
Образования округлой или овальной формы	16
Тень, ассоциированная с микрокальцинатами	8
Всего	608

Для оценки обобщающей способности предложенный ABK тестировался также на цифровых маммограммах, полученных из публичных баз данных (БД) CBIS-DDSM и INbreast, которые не участвовали при разработке алгоритма:

- 257 маммограмм из БД CBIS-DDSM [10] (цифровые маммограммы в формате DICOM);
- 116 маммограмм из БД INbreast [11] (цифровые маммограммы в формате DICOM).

В табл. 2 представлены присутствующие типы изменений МЖ на маммограммах, полученных из публичных БД.

# Табл. 2

Рассмотренные типы изменений МЖ в БД CBIS-DDSM и INbreast

Тип изменения	Количество в CBIS-DDSM	Количество в INbreast
Звездчатые образования	70	30
Образования с нечетким контуром	80	34
Образования с ровным контуром	18	14

Асимметрии	6	4
Частично срезанные образования	10	_
Образования менее 10 мм	73	34
Всего	257	116

Недостатком рассмотренных публичных БД является то, что в них практически отсутствуют плохо видимые и невидимые случаи, представляющие собой основную диагностическую проблему.

Алгоритм обнаружения патологических изменений на маммограммах. Маммограммы представляли собой изображения с глубиной цвета 8 бит и серой шкалой яркости, где пиксели изображения с наибольшей яркостью соответствуют более плотной ткани молочной железы (рис. 1,а), то есть каждый *i*-й пиксель изображения представлен своими координатами  $x_i$ ,  $y_i$  и яркостью  $B = I(x_i, y_i)$ .

Этапы алгоритма.

**Этап 1.** Строятся линии уровня для всего яркостного диапазона маммограммы (рис. 1,б), с постоянным шагом градации *k*:

$$\begin{cases} 1, & I(x, y) = B \ge kn \\ 0, & I(x, y) = B < kn \end{cases}$$

где 0 < kn < 255,  $n = 1, ..., \frac{256}{k}$ , k = const, B = I(x, y)– яркость пикселя изображения, представленного своими координатами (*x*,*y*).

С помощью алгоритма жука (алгоритм обхода бинаризованных пикселей) на каждом шаге гра-



**Рис. 1.** Маммографическое изображение (а) и его линии уровня (б). Стрелка указывает на образование, соответствующее РМЖ

дации *n* обходятся все полученные необнуленные пиксели изображения и сохраняются контуры линий уровня  $U_{n,i}$ , где *n* – текущий шаг по градации яркости, *i* = 1,...,*M*, *M* – количество линий уровня, найденных на *n*-м шаге градации.

Этап 2. Из набора линий уровня последовательно выделяются серии вложенных друг в друга. Если все пиксели рассматриваемой линии уровня находятся внутри области другой линии, полученной на следующем шаге градации, то такая линия является вложенной:

$$\begin{cases} вложенный, \quad \frac{S(U_{n,i} \cap U_{n+1,i})}{S(U_{n,i})} = 1 \\ \text{не вложенный,} \quad \frac{S(U_{n,i} \cap U_{n+1,i})}{S(U_{n,i})} < 1 \end{cases}, \end{cases}$$

где:  $S(U_{n,i})$  – площадь (в пикселях), занимаемая линиями уровня U, полученными на *n*-м шаге градации:  $S(U_{n,i} \cap U_{n+1,j})$  – площадь (в пикселях) области пересечения линий уровня U полученных на *n*-м и *n*+1-м шаге градации яркости.

Этап 3. Рассчитывается набор из геометрических характеристик линий уровня, который был определен по экспериментальным данным, с наименьшим коэффициентом корреляции и меньшей дисперсией:

- 1) длина линии уровня (периметр) *P*, равная количеству пикселей линии уровня *N*;
- 2) компактность C (отношение квадрата периме-

тра к площади линии уровня:  $C = \frac{P^2}{S}$ );

3) координаты центра масс линии уровня:  $1 \frac{N}{N}$   $1 \frac{N}{N}$ 

$$x_c = \frac{1}{N} \sum_{j=1}^{N} x_j, \ y_c = \frac{1}{N} \sum_{j=1}^{N} y_j,$$
 где  $x_j, y_j$ -коорди-

наты *j*-ой точки линии уровня, а *N* – количество точек линии уровня;

 стандартное отклонение расстояний от центра масс линии уровня (x, y) до каждой его

точки: 
$$\sigma = \sqrt{\frac{1}{N} \sum_{j=1}^{N} (r_j - \overline{r})^2}$$
, где  $\overline{r} = \frac{\sum_j^N r_j}{N}$ ,  
 $r_j = \sqrt{(x_j - x_c)^2 + (y_j - y_c)^2}$ .

5) эксцентриситет линии уровня, определяемый

по формуле: 
$$E = \frac{2\sqrt{(0,5A_{\text{max}})^2 - (0,5A_{\text{min}})^2}}{A_{\text{max}}},$$
  
где  $A_{\text{max}} = 2\sqrt{2}\sqrt{U_x + U_y + C},$   
 $A_{\text{min}} = 2\sqrt{2}\sqrt{U_x + U_y - C},$ 

$$C = \sqrt{(U_x - U_y)^2 + 4U_{xy}^2},$$
  

$$U_x = \frac{1}{12} + \frac{1}{N} \sum_{j=1}^{N} (x_i - x_c)^2,$$
  

$$U_y = \frac{1}{12} + \frac{1}{N} \sum_{j=1}^{N} (y_j - y_c)^2,$$
  

$$U_{xy} = \frac{1}{N} \sum_{j=1}^{N} (x_j - x_c)(y_j - y_c).$$

Определены нормированные центральные моменты, инвариантные относительно переноса

и изменения масштаба [12]:  $\eta_{p,q} = \frac{\mu_{p,q}}{m_{0,0}^{(p+q)/2+1}},$ 

где:  $\mu_{p,q} = \sum_{j=1}^{N} (x_j - x_{avg})^p (y_j - y_{avg})^q$ ,  $x_{avg} = m_{1,0} / m_{0,0}, \quad y_{avg} = m_{0,1} / m_{0,0}, \qquad m_{1,0} = \sum_{j=1}^{N} x_j$ ,  $m_{0,1} = \sum_{i=1}^{N} y_i; m_{0,0}$  – нулевой момент равен длине

линии уровня N, p и q – порядок возведения в степень соответствующего параметра при суммировании.

Для оценки степени периодичности линии уровня проведен спектральный анализ величин r:

$$S_k = \left| F(r_j) \right|^2$$
, где  $F$  – преобразование Фурье,  $k$  –

номер гармоники спектра (k = 1,...,N/2). В качестве параметра, характеризующего сложность линии уровня, используется энтропия нормированных

гармоник [13]: 
$$H = -\sum_{k=1}^{N/2} \overline{S}_k \ln \overline{S}_k$$
, где  $\overline{S}_k = \frac{S_k}{\sum_{k=1}^{N/2} S_k} -$ доля мощности.

Этап 4. Определяются меры подобия двух вложенных линий уровня А и В, выделенных на разных градациях яркости *п* для разных геометрических характеристик w, полученных на Этапе 3. Используются четыре меры, включающие разности значений, евклидово расстояние и отношение периметров:

$$K_1(A,B) = \sum_{i=1}^{M} |w_i^A - w_i^B|$$
 и ее относительное  
значение  $K_2(A,B) = \sum_{i=1}^{M} |\frac{w_i^A - w_i^B}{w_i^A}|$ , где  $M$  –

количество моментов (для нормированных цен-

- тральных моментов); 2) отношение  $K_3(A, B) = \frac{w_A}{w_B}$  (для периметра ли-ний уровня);
- 3) евклидово расстояние между центрами масс линий уровня

$$K_4(A,B) = \sqrt{(x_c^A - x_c^B)^2 + (y_c^A - y_c^B)^2};$$

4) абсолютные разности 
$$K_5(A,B) = |w^A - w^B|$$
 (по

всем остальным характеристикам линии уровня).

Критические точки для мер подобия были определены на основе обучающего набора мер подобия, полученных для маммограмм без патологических изменений и с изменениями МЖ. Если контур линии уровня отличается от вложенного, полученного на предыдущем шаге градации *n*-1, делается вывод, что рассматриваемый контур линии уровня представляет собой неподозрительную область и должен быть отброшен. Чем больше найдено подобных серий вложенных контуров линий уровня, тем больше вероятность того, что эта область является подозрительной.

На рис. 2 представлена упрощенная блок-схема предложенного алгоритма. Однако аналогичные статистические характеристики могут иметь и контуры фиброзных (связок Купера) и/или сосудистых структур, что дает ложноположительные результаты для данного алгоритма. Например, наложенные тяжи, как правило, имеют вытянутую форму (рис. 3,б), а подозрительные образования более округлые (рис. 3,а), что позволяет охарактеризовать их контуры по параметру удлинения (эксцентриситету).



Рис. 2. Блок-схема алгоритма обнаружения изменений МЖ

Табл. З



Рис. 3. Подозрительное изменение (а), фиброзный тяж (б) и частично видимое изменение (в)

Были проанализированы экспериментально полученные наборы этого параметра для подозрительных образований, фиброзных тяжей и частично видимых на маммограмме образований, которые также могут иметь удлиненную форму (рис. 3, в). В табл. 3 представлены полученные результаты. Для выборки из 110 эксцентриситетов контура были найдены его среднее значение и медиана.

Средние значения для фиброзных тяжей значительно превышают значения для подозрительного изменения и частично видимого изменения, что позволяет его отделить.

Эксцентричность контуров				
Вид Значение	Волок- нистые ткани			
Среднее	0,582	0,793	0,929	
Медиана	0,570	0,809	0,938	

#### 2. Результаты

Анализ характеристик маммографических изображений, полученных из различных источников. Аналоговые маммограммы. Источником вариабельности характеристик аналоговых изображений являются параметры рентгеновского излучения, генерируемого рентгеновской трубкой и системой фильтров, особенности восприятия рентгеновской пленки и вариация параметров ее последующей обработки. Особенностью аналоговых маммограмм является отсутствие фильтров постобработки изображений. На рис. 4 представлены две пленочные оцифрованные маммограммы и построенные для них гистограммы яркости пикселей изображения МЖ.

Цифровые маммографы позволяют получить сразу цифровое изображение стандартизированного формата DICOM с разрешением 600 DPI, однако в сами программы съема заложены различные методы предобработки изображений, которые основаны на нелинейных фильтрах и могут устанавливаться во время наладки оборудования. Кроме того, они могут меняться в процессе его эксплуатации. Также оборудование разных производи-



Рис. 4. Оцифрованная пленочная маммограмма с разрешением 300 DPI, полученная из частной базы данных (а); оцифрованная маммограмма, полученная из публичной базы данных MIAS [14], разрешение - 72 DPI (б)

телей может использовать разные матрицы детектора, которые имеют разную чувствительность и оптическую плотность, что также сказывается на характеристиках получаемого изображения. Отдельной проблемой является работа системы автоматической установки экспозиции в зависимости от степени поглощения рентгеновского пучка тканями исследуемой области. Это приводит к установке различных режимов работы рентгеновской трубки и, как следствие, является значимой причиной вариабельности получаемых изображений. На рис. 5 представлены три цифровые маммограммы, которые соответствуют одному и тому же типу плотности МЖ, полученные на разных цифровых маммографах, и их гистограммы яркости пикселей изображения.

На рис. 5 видно, что для маммограммы, полученной на системе Siemens Mammomat Fusion, основной фон МЖ расположен в диапазоне низкой яркости от 5 до 165 градаций, медиана гистограммы – 85. Для БД CBIS-DDSM основной фон МЖ расположен в центре диапазона градаций яркости от 15 до 225, медиана – 125. БД INbreast – сильно сжата в диапазоне градаций, МЖ умещается в диапазон от 105 до 205 градаций яркости, медиана – 165.



Рис. 5. Цифровая маммограмма, полученная на системе Siemens Mammomat Fusion [Германия] (а); цифровая маммограмма полученная из публичной БД CBIS-DDSM (б); цифровая маммо-грамма полученная из публичной БД INbreast (в)

Таким образом, из рассмотренных выше примеров можно сделать вывод, что при разработке систем автоматического обнаружения патологических изменений на маммограммах, необходимо использовать адаптивные методы, которые могли бы обобщать новые контексты характеристик изображений, не влияя при этом на качество обнаружения самих патологических изменений. Оценка эффективности ABK. В табл. 4 представлены результаты обнаружения изменений на пленочных маммограммах с помощью ABK. Общая точность обнаружения ABK в исследуемой выборке составила 90,73 % (323 случая из 356). Средняя частота ложных меток составила 1,3 на изображение – для маммограмм жировой степени плотности и 1,8 – для маммограмм высокой степени плотности.

В табл. 5 представлены результаты обнаружения изменений на цифровых маммограммах с помощью ABK. Всего было обработано 252 цифровые маммограммы (126 пациенток). Все ненайденные случаи соответствовали маммограммам в какой-либо одной проекции, тогда как изменения на изображениях во второй проекции были обнаружены. Общая точность обнаружения ABK в исследуемой выборке цифровых маммограмм составила 96,82 % (244 случая из 252).

На рис. 6 представлены маммограммы на которых АВК обнаружил изменения, пропущенные врачом-рентгенологом при визуальном анализе. Врачи-рентгенологи, которым были продемонстрированы маркировки предложенного АВК, изменили свое решение о случае РМЖ на основании результатов работы алгоритма в 6 из 100 случаев, включенных в анализ.

Оценка обобщающей способности и сравнительный анализ. В табл. 6 представлены результаты обработки маммограмм из БД CBIS-DDSM, где присутствовало по два изображения (проекции) на каждую МЖ. Был зафиксирован единственный

#### Табл. 4

Результаты обнаружения изменений АВК на пленочных маммограммах

Тип изменения	Результат обнаружения
Звездчатые образования	205 из 220 (93,18 %)
Спикулизированные с небольшим и плотным центром и длинными спикулами	12 из 14 (85,71 %)
Изменения неправильной формы с нечеткими контурами	51 из 58 (87,93 %)
Дольчатые и круглые с полностью или частично четкими контурами	12 из 12 (100 %)
Частично визуализируемые	17 из 18 (94,4 %)
Асимметрия плотности	13 из 18 (72,2 %)
Нечетко видимые или невидимые	7 из 16 (43,8 %)

#### Табл. 5

Результаты обнаружения изменений АВК на цифровых маммограммах

Тип изменения	Результат обнаружения
Звездчатые образования	102 из 102 (100 %)
Образования округлой или овальной формы	16 из 16 (100 %)
Асимметрии плотности паренхимы	28 из 28 (100 %)
Не визуализирующиеся образования на фоне плотной паренхимы	32 из 38 (84 %)
Частично визуализирующиеся образования	4 из 4 (100 %)
Образования дольчатой формы	46 из 48 (95 %)
Изменение структуры паренхимы	8 из 8 (100 %)
Тень, ассоциированная с микрокальцинатами	8 из 8 (100 %)



**Рис. 6.** Примеры маммограмм на которых разработанный метод АВК обнаружил изменения (белая стрелка), пропущенные врачом-рентгенологом

случай, когда изменение не было промаркировано на обоих изображениях. Во всех остальных случаях изменения не были промаркированы только на одном из изображений, в то время как на другом изображении пары они были промаркированы, что, как представляется, нельзя расценивать как истинно отрицательный результат работы алгоритма.

В табл. 7 представлены результаты обработки маммограмм из БД INbreast. В базе INbreast изменения, соответствующие РМЖ, не были промаркированы на пяти изображениях, однако случаев, когда они не были промаркированы на обоих изображениях одной МЖ, не было.

Результаты, приведенные в табл. 6 и 7, демонстрируют, что, несмотря на различие характеристик изображений, полученных из разных БД,

					Tab	іл. 6
Результаты	работы л	ABK	на	маммограмм	ах из	БД
	С	BIS-I	DD	SM		

Тип изменения	Результат обнаружения
Звездчатые образования	69 из 70 (98 %)
Образования с нечетким контуром	78 из 80 (97 %)
Образования с ровным контуром	17 из 18 (94 %)
Асимметрии	6 из 6 (100 %)
Частично срезанные образования	10 из 10 (100 %)
Образования менее 10 мм	70 из 73 (95 %)
Всего	250 из 257 (97 %)

### Табл. 7

Результаты работы ABK на маммограммах из БД INbreast

Тип изменения	Результат обнаружения
Звездчатые образования	30 из 30 (100 %)
Образования с нечетким контуром	32 из 34 (94 %)
Образования с ровным контуром	13 из 14 (92 %)
Асимметрии	4 из 4 (100 %)
В том числе: образования менее 10 мм	32 из 34 (94 %)
Всего	111 из 116 (95,6 %)

предложенный АВК показывает высокую точность в обнаружении патологических изменений на них.

Дополнительно проведено сравнение предложенного АВК с другими современными мето-

Табл.	8
-------	---

База данных	Методы и источники	Год	Точность (%)
CBIS-DDSM	Shams S. и др. [15], Deep GeneRAtive Multi-task сверточная нейронная сеть.	2018	89 %
CBIS-DDSM	Tsochatzidis L. и др. [16], контролируемый подход к поиску объектов на изображении на основе его контента.	2019	81 %
CBIS-DDSM	Falconi L. и др. [17], сеть глубокого обучения VGG16.	2020	84,4 %
CBIS-DDSM	Ansar W. и др. [18], сеть глубокого обучения на основе MobileNet.	2020	74,5 %
CBIS-DDSM	Zhang Н. и др. [19], классификация с кросс-модальным семантическим анализом.	2020	87,05 %
CBIS-DDSM	Himanish S.D. и др. [20], классификатор Xception с тонкой настройкой.	2022	89,2 %
CBIS-DDSM	Li H. [7], DualCoreNet.	2022	93 %
CBIS-DDSM	Предложенный алгоритм	2022	97 %
CBIS-DDSM	Jafari Z. и др. [8], CNN с выбором признаков.	2023	96%
INbreast	Dhungel N. и др. [21], каскад методов глубокого обучения.	2017	90 %
INbreast	Carneiro G. и др. [22], сверточная нейронная сеть ConvNet.	2017	90 %
INbreast	Shi P. и др. [23], сверточная нейронная сеть.	2019	83,6 %
INbreast	Zhang H. и др. [19], классификация с кросс-модальным семантиче- ским анализом.	2020	87,93 %
INbreast	El Houby E.M. и др. [24], сверточная нейронная сеть.	2021	94,52 %
INbreast	Himanish S.D. и др. [20], классификатор Xception с тонкой настройкой.	2022	95,1 %
INbreast	Предложенный алгоритм	2022	95,6 %
INbreast	Jafari Z. и др. [8], CNN с выбором признаков.	2023	94,5 %

#### Сравнение АВК со современными методиками

диками обнаружения патологических изменений на маммограммах полученных из публичных баз данных.

Из табл. 8 видно, что предложенный ABK превосходит современные методики обнаружения изменений МЖ, несмотря на различия характеристик изображений, на которых он разрабатывался и тестировался.

# Заключение

Проведенные исследования демонстрируют высокую чувствительность разработанного АВК не только в случаях типичных и четко видимых образований, но и в случаях атипичных и невидимых патологических изменений. В то же время АВК потенциально способен обнаружить образования на маммографических изображениях, характеристики которых могут варироваться в широких пределах, что показывает высокую обобщающую способность алгоритма. С этой точки зрения представляется разумным использовать АВК в качестве части автоматической системы 2-го или 3-го анализа, чтобы отметить подозрительные зоны для их последующего детального исследования. Этот подход, вероятно, может повысить выявляемость РМЖ и, следовательно, исходы лечения в таких случаях. В то же время АВК нечувствителен к скоплениям микрокальцинатов, что требует включения дополнительного алгоритма в конструкцию системы автоматизированного анализа маммограмм. В качестве такого алгоритма может быть использована методика, ранее предложенная в работе [25]. В перспективе целесообразно разработать методы фильтрации ложноположительных результатов и, следовательно, повышения точности АВК.

# Литература

- Ferlay J., Soerjomataram I., Ervik M., Dikshit R., Eser S., Mathers C., Rebelo M., Parkin D.M., Forman D., Bray F. GLOBOCAN 2012 v1.1, Cancer Incidence and Mortality Worldwide: IARC CancerBase. No. 11. Lyon, France: International Agency for Research on Cancer, 2014. Available from: http://globocan.iarc.fr/ [Accessed 16 January 2024].
- 2. United States Preventive Services Task Force. Screening for breast cancer: U.S. Preventive Services Task Force recommendation statement, Annals of Internal Medicine. 2009. 151. P. 716-726.
- 3. Пасынков Д.В., Егошин И.А., Колчев А.А., Клюшкин И.В., Пасынкова О.О. Эффективность

системы компьютерного анализа маммограмм в диагностике вариантов рака молочной железы, трудно выявляемых при скрининговой маммо-графии // Российский электронный журнал лучевой диагностики. 2019. Т.9. №2. С. 107-118. DOI:10.21569/2222-7415-2019-9-2-107-118

- 4. Васильев Ю.А., Тыров И.А., Владзимирский А.В., Арзамасов К.М., Шулькин И.М., Кожихина Д.Д., Пестренин Л.Д. Двойной просмотр результатов маммографии с применением технологий искусственного интеллекта: новая модель организации массовых профилактических исследований // Digital Diagnostics. 2023. Т.4. №2. С. 93-104. DOI:10.17816/DD321423
- Singh N., Veenadhari S. Breast cancer segmentation using global thresholding and region merging. International Journal of Computer Sciences and Engineering. 2018. 6(12). P. 292-297. DOI:10.26438/ijcse/v6i12.292297
- 6. *Podgornova Y.A., Sadykov S.S.* Comparative analysis of segmentation algorithms for the allocation of microcalcifications on mammograms. Information Technology and Nanotechnology. 2019. 2391. P 121-127. DOI:10.18287/1613-0073-2019-2391-121-127
- Li H., Chen D., Nailon W.H., Davies M.E., Laurenson D.I. Dual convolutional neural networks for breast mass segmentation and diagnosis in mammography. IEEE Trans Med Imaging. 2022. 41(1). P. 3-13. DOI:10.48550/arXiv.2008.02957
- Jafari Z., Karami E. Breast Cancer Detection in Mammography Images: A CNN-Based Approach with Feature Selection. Information. 2023. 14(7). P. 1-14. DOI:10.3390/info14070410
- Egoshin I., Pasynkov D., Kolchev A., Kliouchkin I., Pasynkova O. A segmentation approach for mammographic images and its clinical value. IEEE International Conference on Microwaves, Antennas, Communications and Electronic Systems, COMCAS 2017; 2018. P. 1-6. DOI:10.1109/COMCAS.2017.8244764
- Lee R.S., Gimenez F., Hoogi A., Miyake K.K., Gorovoy M., Rubin D.L. A curated mammography data set for use in computer-aided detection and diagnosis research. Sci Data. 2017. 4. P. 170177. DOI:10.1038/sdata.2017.177
- 11. Moreira I.C., Amaral I., Domingues I., Cardoso A., Cardoso M.J., Cardoso J.S. INbreast: toward a full-field digital mammographic database. Acad Radiol. 2012. 19(2). P. 236-248. DOI: 10.1016/j. acra.2011.09.014
- 12. *Flusser J., Zitova B., Suk T.* Moments and Moment Invariants in Pattern Recognition. New York: John Wiley and Sons. 2009. 312 p.

- Останин С.А., Шайдук А.М., Козлов Д.Ю., Коновалов В.К., Леонов С.Л., Федоров В.В., Шойхет Я.Н., Колмогоров В.Г., Лобанов М.Н. Энтропийный метод оценки сложности контура медицинских изображений // Известия Алтайского государственного университета. 2013. Т.1/2. №77. С. 177-180. DOI:10.14258/ izvasu(2013)1.2-36
- Suckling J., Parker J., Dance D. The Mammographic Image Analysis Society Digital Mammogram Database Exerpta Medica. International Congress Series. 1994. 1069. P. 375-378.
- Shams S., Platania R., Zhang J., Kim J., Lee K., Park S.J. Deep generative breast cancer screening and diagnosis. International Conference on Medical Image Computing and Computer-Assisted Intervention, Granada, Spain. 2018. P. 859-867. DOI: 10.1007/978-3-030-00934-2\_95
- Tsochatzidis L., Costaridou L., Pratikakis I. Deep learning for breast cancer diagnosis from mammograms—A comparative study. J. Imaging. 2019. 5(3). P. 1-11. DOI:10.3390/jimaging5030037
- Falconi L.G., Perez M., Aguilar W.G., Conci A. Transfer learning and fine tuning in breast mammogram abnormalities classification on CBIS-DDSM database. Adv. Sci. Technol. Eng. Syst. J. 2020. 5. P. 154-165. DOI:10.25046/ aj050220
- Ansar W., Shahid A.R., Raza B., Dar A.H. Breast cancer detection and localization using mobilenet based transfer learning for mammograms. International symposium on intelligent computing systems, Sharjah, United Arab Emirates. 2020. P. 11-21. DOI:10.1007/978-3-030-43364-2 2
- 19. Zhang H., Wu R., Yuan T., Jiang Z., Huang S., Wu J., Hua J., Niu Z., Ji D. DE-ada\*: A novel

model for breast mass classification using crossmodal pathological semantic mining and organic integration of multi-feature fusions. Inf. Sci. 2020. 539. P. 461-486. DOI:10.1016/j.ins.2020.05.080

- Himanish D., Akalpita D., Anupal N., Saurav M., Kangkana B., Zhongming Z. Breast cancer detection: Shallow convolutional neural network against deep convolutional neural networks based approach. Frontiers in Genetics. 2023. 13. P. 1097207. DOI:10.3389/fgene.2022.1097207
- Dhungel N., Carneiro G., Bradley A.P. A deep learning approach for the analysis of masses in mammograms with minimal user intervention. Med. image Anal. 2017. 37. P. 114-128. DOI:10.1016/j.media.2017.01.009
- Carneiro G., Nascimento J., Bradley A.P. Automated analysis of unregistered multi-view mammograms with deep learning. IEEE Trans. Med. imaging. 2017. 36(11). P. 2355-2365. DOI:10.1109/TMI.2017.2751523
- Shi P., Wu C., Zhong J., Wang H. Deep learning from small dataset for BI-RADS density classification of mammography images. In 2019 10th International Conference on Information Technology in Medicine and Education (ITME), Qingdao, China. 2019. P. 102-109. DOI:10.1109/ ITME.2019.00034
- El Houby E.M., Yassin N.I. Malignant and nonmalignant classification of breast lesions in mammograms using convolutional neural networks. Biomed. Signal Process. 2021. 70. P. 102954. DOI:10.1016/j.bspc.2021.102954
- 25. Пасынков Д.В., Егошин И.А., Колчев А.А., Романычева Е.А., Клюшкин И.В., Пасынкова О.О. Обнаружение и классификация скоплений микрокальцинатов на маммографических изображениях // Медицинская техника. 2024. №1. С. 29-32.

Егошин Иван Александрович. Морийский государственный университет, г. Йошкар-Ола, Россия. Младший научный сотрудник. Область научных интересов: цифровая обработка изображений, методы глубокого обучения, математическое моделирование. E-mail: jungl91@mail.ru

# Evaluation of an generalization ability of the nested contours algorithm in the mammograms analysis

# I.A. Egoshin

Federal State Budgetary Educational Institution of Higher Education "Mari State University", Yoshkar-Ola, Russia

Abstract. The work presents an nested contours algorithm designed for detecting pathological changes that may correspond to breast cancer on X-ray mammographic images, and provides the results of evaluating its generalization ability. This algorithm was tested on a large dataset of mammographic images with all possible variations of changes corresponding to verified breast cancer, including faintly visible and invisible ones. The overall detection accuracy of the algorithm was 90.73% for film and 96.82% for digital mammograms. A comparative analysis of using this algorithm and other modern methods of change detection on mammograms, with publicly available databases (INbreast and CBIS-DDSM), is also provided. The higher accuracy of the differences in mammogram characteristics obtained from different systems, indicates the high generalization ability of the proposed algorithm.

**Keywords:** *breast cancer, mammography, detection, level lines, generalization ability.* **DOI:** 10.14357/20790279240308 **EDN: NXRKLK** 

# References

- Ferlay J., Soerjomataram I., Ervik M., Dikshit R., Eser S., Mathers C., Rebelo M., Parkin D.M., Forman D., Bray F. GLOBOCAN 2012 v1.1, Cancer Incidence and Mortality Worldwide: IARC CancerBase. No. 11. Lyon, France: International Agency for Research on Cancer, 2014. Available from: http://globocan.iarc.fr/ [Accessed 16 January 2024].
- 2. United States Preventive Services Task Force. Screening for breast cancer: U.S. Preventive Services Task Force recommendation statement, Annals of Internal Medicine. 2009; 151: 716-726.
- Pasynkov D.V., Egoshin I.A., Kolchev A.A., Kliouchkin I.V., Pasynkova O.O. The value of computer aided detection system in breast cancer difficult to detect at screening mammography. REJR. 2019; 9(2): 107-118 (In Russ). doi:10.21569/2222-7415-2019-9-2-107-118
- 4. Vasilev Yu.A., Tyrov I.A., Vladzymyrskyy A.V., Arzamasov K.M., Shulkin I.M., Kozhikhina D.D., Pestrenin L.D. Double-reading mammograms using artificial intelligence technologies: A new model of mass preventive examination organization. Digital Diagnostics. 2023; 4(2): 93-104 (In Russ). doi:10.17816/DD321423
- Singh N., Veenadhari S. Breast cancer segmentation using global thresholding and region merging. International Journal of Computer Sciences and Engineering. 2018; 6(12): 292-297. doi:10.26438/ ijcse/v6i12.292297
- 6. *Podgornova Y.A., Sadykov S.S.* Comparative analysis of segmentation algorithms for the allocation of microcalcifications on mammograms.

Information Technology and Nanotechnology. 2019; 2391: 121-127. doi:10.18287/1613-0073-2019-2391-121-127

- Li H., Chen D., Nailon W.H., Davies M.E., Laurenson D.I. Dual convolutional neural networks for breast mass segmentation and diagnosis in mammography. IEEE Trans Med Imaging. 2022; 41(1): 3-13. doi:10.48550/arXiv.2008.02957
- Jafari Z., Karami E. Breast Cancer Detection in Mammography Images: A CNN-Based Approach with Feature Selection. Information. 2023; 14(7): 1-14. doi:10.3390/info14070410
- Egoshin I., Pasynkov D., Kolchev A., Kliouchkin I., Pasynkova O. A segmentation approach for mammographic images and its clinical value. IEEE International Conference on Microwaves, Antennas, Communications and Electronic Systems, COMCAS 2017; 2018. p. 1-6. doi:10.1109/COMCAS.2017.8244764
- 10. Lee R.S., Gimenez F., Hoogi A., Miyake K.K., Gorovoy M., Rubin D.L. A curated mammography data set for use in computer-aided detection and diagnosis research. Sci Data. 2017; 4:170-177. doi:10.1038/sdata.2017.177
- 11. Moreira I.C., Amaral I., Domingues I., Cardoso A., Cardoso M.J., Cardoso J.S. INbreast: toward a full-field digital mammographic database. Acad Radiol. 2012; 19(2): 236-248. doi: 10.1016/j. acra.2011.09.014
- 12. *Flusser J., Zitova B., Suk T.* Moments and Moment Invariants in Pattern Recognition. New York: John Wiley and Sons; 2009. 312 p.

- Ostanin S.A., Shayduk A.M., Kozlov D.Yu., Konovalov V.K., Leonov S.L., Fedorov V.V., Shoikhet Ya.N., Kolmogorov V.G., Lobanov M.N. Entropy method for estimating the complexity of edge medical images. The News of Altai State University. 2013; 1/2(77): 177-180 (In Russ). doi:10.14258/izvasu(2013)1.2-36
- Suckling J., Parker J., Dance D. The Mammographic Image Analysis Society Digital Mammogram Database Exerpta Medica. International Congress Series. 1994; 1069: 375-378.
- Shams S., Platania R., Zhang J., Kim J., Lee K., Park S.J. Deep generative breast cancer screening and diagnosis. International Conference on Medical Image Computing and Computer-Assisted Intervention, Granada, Spain; 2018. p. 859-867. doi: 10.1007/978-3-030-00934-2\_95
- Tsochatzidis L., Costaridou L., Pratikakis I. Deep learning for breast cancer diagnosis from mammograms—A comparative study. J. Imaging. 2019; 5(3): 1-11. doi:10.3390/jimaging5030037
- Falconi L.G., Perez M., Aguilar W.G., Conci A. Transfer learning and fine tuning in breast mammogram abnormalities classification on CBIS-DDSM database. Adv. Sci. Technol. Eng. Syst. J. 2020; 5: 154-165. doi:10.25046/aj050220
- Ansar W., Shahid A.R., Raza B., Dar A.H. Breast cancer detection and localization using mobilenet based transfer learning for mammograms. International symposium on intelligent computing systems, Sharjah, United Arab Emirates; 2020. p. 11-21. doi:10.1007/978-3-030-43364-2 2
- 19. Zhang H., Wu R., Yuan T., Jiang Z., Huang S., Wu J., Hua J., Niu Z., Ji D. DE-ada\*: A novel model for breast mass classification using cross-

modal pathological semantic mining and organic integration of multi-feature fusions. Inf. Sci. 2020; 539: 461-486. doi:10.1016/j.ins.2020.05.080

- Himanish D., Akalpita D., Anupal N., Saurav M., Kangkana B., Zhongming Z. Breast cancer detection: Shallow convolutional neural network against deep convolutional neural networks based approach. Frontiers in Genetics. 2023; 13: 1097207. doi:10.3389/fgene.2022.1097207
- Dhungel N., Carneiro G., Bradley A.P. A deep learning approach for the analysis of masses in mammograms with minimal user intervention. Med. image Anal. 2017; 37: 114-128. doi:10.1016/j.media.2017.01.009
- 22. Carneiro G., Nascimento J., Bradley A.P. Automated analysis of unregistered multiview mammograms with deep learning. IEEE Trans. Med. imaging. 2017; 36(11): 2355-2365. doi:10.1109/TMI.2017.2751523
- Shi P., Wu C., Zhong J., Wang H. Deep learning from small dataset for BI-RADS density classification of mammography images. In 2019 10th International Conference on Information Technology in Medicine and Education (ITME), Qingdao, China; 2019. p. 102-109. doi:10.1109/ ITME.2019.00034
- El Houby E.M., Yassin N.I. Malignant and nonmalignant classification of breast lesions in mammograms using convolutional neural networks. Biomed. Signal Process. 2021; 70: 102954. doi:10.1016/j.bspc.2021.102954
- Pasynkov D.V., Egoshin I.A., Kolchev A.A., Romanycheva E.A., Kliouchkin I.V., Pasynkova O.O. Detection and Classification of Microcalcifications in Mammographic Images. Meditsinskaya tekhnika. 2024; 1: 29-32 (In Russ).

Egoshin Ivan A. Junior researcher, Federal State Budgetary Educational Institution of Higher Education "Mari State University", 1 Lenin square, Yoshkar-Ola, Russia. E-mail: jungl91@mail.ru