

Санкт–Петербургский государственный университет

*Сенаторова Наталия Максимовна*

**Выпускная квалификационная работа**

*Уточнение онкологического диагноза с помощью современных технологий распознавания изображений*

Уровень образования: бакалавриат

Направление 01.03.02 «Прикладная математика и информатика»

Основная образовательная программа СВ.5005.2018 «Прикладная математика, фундаментальная информатика и программирование»

Профиль «Исследование и проектирование систем управления и обработки сигналов»

Научный руководитель:

профессор, кафедра компьютерного моделирования и многопроцессорных систем,  
д.т.н. Щеголева Надежда Львовна

Рецензент:

доцент, Лаборатория технологий больших данных социкиберфизических систем,  
д.т.н. Жукова Наталия Александровна

Санкт-Петербург

2022 г.

# Содержание

<b>Введение</b> . . . . .	3
<b>Постановка задачи</b> . . . . .	4
<b>Обзор литературы</b> . . . . .	5
<b>Глава 1. Извлечение признаков из изображений</b> . . . . .	10
1.1. Характеристики датасета . . . . .	10
1.2. Статистики первого порядка . . . . .	12
1.3. Полутоновая матрица смежности . . . . .	13
1.4. Локальные бинарные шаблоны . . . . .	14
1.5. Энергетические характеристики Лавса . . . . .	15
1.6. Моменты Цернике . . . . .	16
1.7. Инвариантные моменты . . . . .	18
<b>Глава 2. Способы классификации изображений</b> . . . . .	20
2.1. Случайный лес . . . . .	20
2.2. AdaBoost . . . . .	20
2.3. Метод k-ближайших соседей . . . . .	20
2.4. Метод опорных векторов . . . . .	21
2.5. Многослойный перцептрон . . . . .	21
<b>Глава 3. Описание экспериментов</b> . . . . .	22
3.1. Архитектура системы . . . . .	22
3.2. Инструментарий . . . . .	22
3.3. Эксперименты . . . . .	23
<b>Глава 4. Анализ результатов</b> . . . . .	27
<b>Заключение</b> . . . . .	29
<b>Список использованных источников</b> . . . . .	31

## Введение

Рак молочной железы является одним самых распространенных видов онкологии в мире. По статистике Всемирной Организации Здравоохранения [1] в 2020 году рак груди был обнаружен у более 2,2 миллиона женщин, а количество смертей составило более 685 тысяч. Более того, за последние несколько десятилетий средний возраст возникновения опухолей сильно снизился. Так как сейчас причины возникновения этого заболевания не до конца ясны, на данный момент не существует достаточно эффективных средств его предотвращения. Однако ранняя диагностика заболевания значительно увеличивает шансы на полное восстановление. Чаще всего для такой диагностики врачи используют маммографические снимки, позволяющие анализировать текстуру ткани груди. Тем не менее, по статистике радиологи не обнаруживают значительную часть аномалий в дополнение к высокому уровню ложноположительных результатов по различным причинам (малый опыт радиолога или плохое качество изображений).

В связи с этим получает широкое распространение разработка систем компьютерного обнаружения и диагностики для повышения точности работы врачей, что требует реализации извлечения текстурных, статистических и структурных признаков из областей изображения и обработки этих признаков с помощью алгоритмов машинного обучения, хотя часто такие системы могут лишь провести бинарную классификацию (наличие или отсутствие рака), но не определить конкретный вид аномалии. Например, скопление микрокальцинатов в молочной железе может быть фактором, говорящим о наличии заболевания, но не всегда оно означает рак.

Так как текстуру тканей груди человеку анализировать сложнее, чем, например, цвет, часто вывод о диагнозе делается на основе границ и очертаний масс или подозрительных областей, но такой признак не всегда является точным, например, поражения тканей не обязательно имеют четкие контуры. Таким образом, разработка систем, анализирующих текстурные признаки снимков, может помочь специалистам в постановке более точного диагноза.

## **Постановка задачи**

Целью данной работы является разработка системы поддержки решений врача-онколога, использующей машинное обучение, а также извлечение текстурных и статистических признаков изображения, для классификации маммографических снимков в зависимости от присутствия или отсутствия на них аномалий. Осуществление цели работы предполагает решение следующих задач:

- поиск и анализ существующих решений задачи, оценка современного состояния вопроса;
- изучение методов извлечения текстурных, статистических и других признаков из изображений;
- реализация извлечения признаков и классификации маммографических снимков с помощью алгоритмов машинного обучения; анализ результатов, полученных с помощью разработанной системы.

## Обзор литературы

За последние несколько лет многими исследователями были предложены различные варианты систем для диагностики рака с помощью маммографических изображений. В основном разработанные системы опираются на традиционное машинное обучение и глубокое обучение; также многие авторы используют методы извлечения признаков (часто текстурных, статистических и геометрических) изображений для улучшения результатов. Далее приведены примеры подобных систем для решения поставленной задачи.

Некоторые исследователи пробуют разработать методологию, которая совмещает в себе использование нескольких видов признаков, например, текстурные признаки и дескрипторы особых точек. Так, система для распознавания злокачественных и доброкачественных масс, разработанная С. Матосом в 2018 году [3], применяет к каждому изображению из датасета дескрипторы SIFT (Scale-Invariant Feature Transform), SURF (Speed Up Robust Features), ORB (Oriented FAST and Rotated BRIEF), а также использует сочетание метода локальных бинарных шаблонов (Local Binary Pattern — LBP) и SIFT. В связи с большим количеством особых точек автор предлагает использовать модель Bag of Features для репрезентации данных. Полученные векторы признаков подаются на вход следующим классификаторам: метод опорных векторов (Support Vector Machine, SVM), Adaptive Boosting (AdaBoost) и случайный лес; сравнивается эффективность всех комбинаций дескрипторов и классификаторов. В результате были получены значения точности 99%, чувствительности 100% и специфичности 99%; лучший результат показала комбинация SIFT-LBP и AdaBoost.

С. Д. Рой и С. Дас в 2021 году предложили систему [4], в которой используется сочетание нескольких методов извлечения признаков (характеристики Харалика) и дескрипторов (SIFT, SURF и ORB), которые пропускают через несколько классификаторов, и затем используют стекинг моделей для увеличения точности бинарной классификации изображений гистологического исследования молочных желез. В результате авторы получают максимальную точность 92,55%. В процессе авторы также изучали работу различных дескрипторов в комбинации друг с другом (соединение двух векторов призна-

ков в один); итоговая точность не превысила порог 88% для всех комбинаций со всем представленными классификаторами, то есть конкатенация векторов признаков не позволила улучшить работу системы.

А. Пхадке и П. Реге в 2016 опубликовали результаты работы системы для классификации аномалий на маммограммах из датасета mini-MIAS (The mammographic image analysis society), которая использует сочетание признаков глобальных (со всего изображения) и локальных (из области интереса) [5]. Из глобальных признаков использовались энергитические характеристики Лавса, энергитические характеристики, полученные с помощью фильтра Габора и фрактальная размерность для оценки "шероховатости" текстуры, а из локальных — моменты Чебышева и полутоновая матрица смежности. Для классификации полученных признаков был использован метод опорных векторов. Авторы показали, что подобное совместное использование признаков увеличивает точность до 93,17%.

М. Хуссейн в 2012 [6] исследовал применение фильтра Габора к маммографическим изображениям для выделения аномалий, а также классификации злокачественных и доброкачественных масс. В работе использовались изображения области интереса в разных разрешениях, к которым применялись фильтры с различным количеством ориентаций, а затем статистические признаки, подсчитанные для каждого сегмента области интереса, классифицировались с помощью SVM. В результате лучшую точность 96% для задачи распознавания аномалий показало использование фильтра Габора с пятью ориентациями.

С. Роча в 2014 [7] предложил систему, основанную на извлечении исключительно текстурных признаков из снимков датасета DDSM (the Digital Database for Screening Mammography). Автор работы использовал полутоновую матрицу смежности для получения признаков, а также использовал два индекса разнообразия для выделения паттернов в текстуре. Для классификации использовалась SVM; лучший результат был достигнут при использовании индекса Глисона с итоговыми показателями точности 86,66%, чувствительности 90% и специфичности 83,33%.

В работе 2015 года за авторством Ш. Шарма для обнаружения опухолей на маммограммах используются моменты Цернике [8], инвариантные отно-

сительно поворота и устойчивые к шуму, что позволяет распознать злокачественные новообразования на изображении под любым углом; для классификации был применен метод опорных векторов. Автор сравнил эффективность работы на двух датасетах, и на одном из них были достигнуты показатели 99% чувствительности и 99% специфичности.

В. Сингх в 2016 году использовал метрики, полученные из полутонной матрицы смежности, для классификации маммограмм с аномалиями и без них [9]. Более того, наиболее важные признаки были выбраны с помощью метода AdaBoost; затем параллельно проводилась классификация всех признаков и признаков, выделенных AdaBoost, и решение принималось на основании этих двух результатов. В результате такого подхода были достигнуты точность 89,02%, чувствительность 90,56% и специфичность 86,40%.

М. Мадхави для задачи классификации ткани груди из датасета mini-MIAS выбрал использование фильтра Габора [10]. После подсчета метрик изображений (энтропия, контраст и другие) наиболее значимые признаки выбирались с помощью анализа основных компонент ядра и метода обертки. В качестве классификаторов использовались случайный лес и метод опорных векторов с наименьшим квадратом; в результате были достигнуты показатели 91,45% точности, 96,89% чувствительности и 80,92% специфичности.

А. Фархан для уменьшения уровня ложноположительных результатов при обнаружении опухолей на маммограммах использовал анализ текстур с помощью локальных бинарных шаблонов [11]. Значения характеристик, полученные благодаря этому методу, используются как входные данные для логистической регрессии в качестве классификатора. В результате получены точность 85.5%, специфичности 95% и чувствительности 73%. Сам автор отмечает, что данный метод стоит совмещать с другими для повышения эффективности.

Т. Дезерно для решения задачи классификации маммограмм по показателю BI-RADS (шкала оценки результатов маммографии по степени риска наличия злокачественных новообразований) применил двумерный метод главных компонент (2-D Principal Components Analysis, 2DPCA) в сочетании с методом опорных векторов [12], в результате чего добился итоговой точности 80%. Хотя во время экспериментов при увеличении количества классов

общая точность уменьшалась, автор отметил перспективность описанного подхода.

Группа исследователей во главе с Я. Хао [13] сравнила разные подходы к извлечению признаков гистопатологических изображений для постановки диагноза. Среди выбранных для анализа методов представлены две вариации полутоновой матрицы смежности, локальные бинарные шаблоны, признаки Тамуры, фильтр Габора и метод гистограммы ориентированных градиентов, а также среднее значение пикселя каждого канала. Каждый вектор признаков отдельно классифицировался с помощью метода опорных векторов; в результате анализа полученных данных выяснилось, что наибольшую эффективность показала полутоновая матрица смежности, правильно диагностировав 94,24% пациентов из выбранного датасета.

Ш. Юун для решения задачи классификации маммографических снимков использовала текстурные характеристики в виде статистик первого порядка и полутоновой матрицы смежности для получения статистик второго порядка [14]; для классификации с помощью многослойного перцептрона (Multilayer Perceptron, MLP) также использовалась комбинация полученных статистик. В результате обучения более эффективными оказались статистики второго порядка. Многослойный перцептрон в задаче классификации доброкачественных и злокачественных аномалий также использовался в [15], где в качестве дескрипторов тоже использовались характеристики, полученные из полутоновой матрицы смежности; в итоге были достигнуты показатели чувствительности 91,67% и специфичности 84,17%.

Р. Рухи решала одновременно задачу сегментации и классификации [16]: сначала опухоль на изображении сегментировалась двумя способами (с помощью разных нейронных сетей), а затем полученное изображение классифицировалось как снимок со злокачественным или доброкачественным образованием. На этапе классификации использовалось извлечение нескольких признаков: статистики первого порядка, характеристики, полученные с помощью полутоновой матрицы смежности, и моменты Цернике вплоть до четвертого порядка: классификация производилась с помощью многослойного перцептрона. Предложенные способы были опробованы на наборах изображений MIAS и DDSM; наилучшую точность 96,47% система показала на

датасете DDSM.

М. Алоби и А.Ахмед в 2017 опубликовали работу [17], в которой использовалось несколько классификаторов (Decision Tree, SVM, метод k-ближайших соседей, наивный байесовский классификатор и Artificial Neural Network), а затем решение о классификации аномалии на маммограмме принималось с помощью голосования; в качестве признаков использовались подсчитанные для каждого изображения контраст, гладкость, стандартное отклонение и три других метрики. Каждый классификатор по отдельности показывал неудовлетворительно низкую точность (около 50–60%), однако после голосования точность работы системы значительно повышалась; максимальная полученная точность составила 87,5%. Таким образом, метод голосования дает многообещающие результаты и возможно повысить точность, используя более сложные методы для описания текстуры изображения.

После обзора литературы по теме можно сделать вывод, что метода, который давал бы стопроцентную точность диагностики маммографических снимков, не существует, и исследователи до сих пор находятся в поиске такой архитектуры системы, которая бы увеличивала точность диагностики. Из подробного изучения приведенных работ можно сделать наблюдение, что системы, использующие только один метод извлечения признаков, чаще оказываются менее точными, чем те, которые используют комбинацию методов. Также по анализу показателей чувствительности и специфичности (первый параметр характеризует, сколько больных объектов было классифицировано как больные, второй — сколько здоровых объектов как здоровые), что специфичность как правило снижена по сравнению с чувствительностью; это означает, что многих описанных выше систем есть риск ложноположительного диагноза.

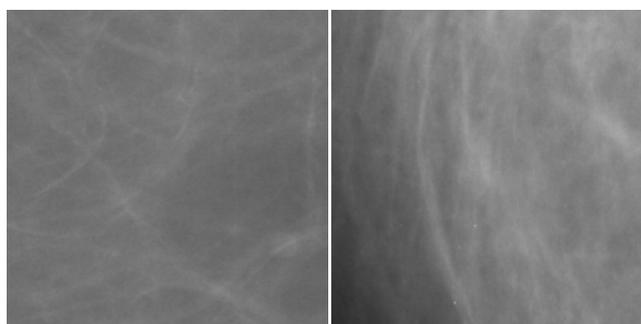
# Глава 1. Извлечение признаков из изображений

## 1.1 Характеристики датасета

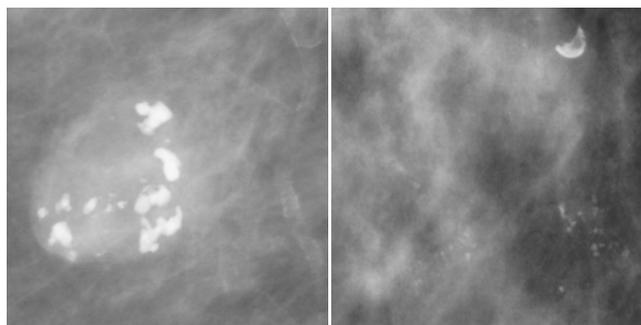
Для решения поставленной задачи были использованы изображения из датасета, состоящего из наборов изображений DDSM и CBIS-DDSM (Curated Breast Imaging Subset of DDSM), широко использующихся для задач автоматической диагностики. Изображения с отрицательным диагнозом были взяты из DDSM, с положительным — из CBIS-DDSM. Каждая маммограмма из обоих датасетов была разбита на сегменты размером 598x598 пикселей; затем размер каждого сегмента был изменен до 299x299, и каждому были присвоены метки в зависимости от присутствия на нем аномалии. Для каждого изображения в наборе присутствует два вида меток. Первый вид — это 1 или 0 (присутствует ли на снимке аномалия или нет), а второй относит изображение к одному из пяти классов:

- 0 — здоровая грудь;
- 1 — доброкачественная кальцификация тканей;
- 2 — доброкачественная опухоль;
- 3 — злокачественная кальцификация;
- 4 — злокачественная опухоль;

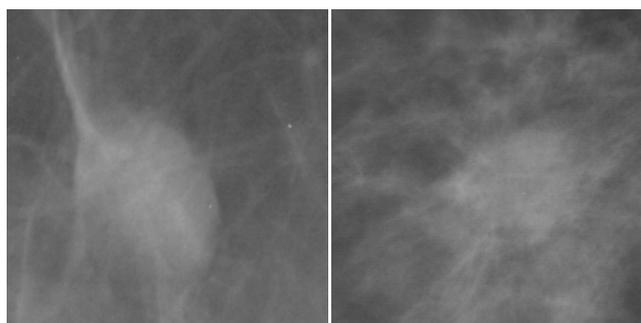
Датасет доступен в сети Интернет и свободно распространяется [18]. Примеры изображений разных классов из датасета представлены на Рисунках 1, 2, и 3.



**Рис. 1:** Примеры изображений без аномалий

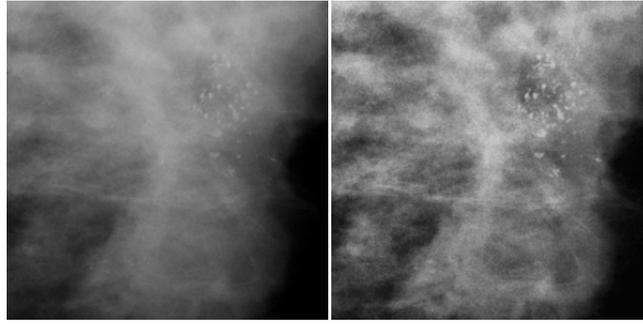


**Рис. 2:** Примеры изображений со доброкачественной (слева) и злокачественной кальцификацией тканей (справа)



**Рис. 3:** Примеры изображений со доброкачественной (слева) и злокачественной опухолью (справа)

Всего было использовано 6177 изображений из датасета, из которых на 1511 изображениях присутствуют аномалии (443 с доброкачественной и 278 со злокачественной кальцификацией тканей; 380 с доброкачественной и 410 со злокачественной опухолью). В силу особенностей создания маммографических снимков изображения из датасета обладают достаточно низкой контрастностью. В связи с этим все снимки из набора предварительно обрабатываются с помощью алгоритма CLAHE (Contrast Limited Adaptive Histogram Equalization) [19]. Этот метод направлен на уменьшение шума и увеличение контрастности, и изначально был разработан для улучшения медицинских изображений. CLAHE работает не со всем изображением, а с небольшими его областями; контраст каждой области увеличивается так, чтобы на выходе значения гистограммы этой области не были выше определенного значения. Затем отдельные области объединяются с использованием билинейной интерполяции для устранения искусственно созданных границ. Результат применения алгоритма представлен на Рисунке 4.



**Рис. 4:** Результат применения алгоритма CLANE

## 1.2 Статистики первого порядка

Статистики первого порядка (First-Order Statistics, FOS) — это метод извлечения текстурных признаков, основанный на характеристиках гистограммы изображения. Пусть дано изображение  $f(x, y)$  в градациях серого. Гистограмма первого порядка  $H_i$  определяется как

$$H_i = \frac{N_i}{N}, \quad (1)$$

где  $N_i$  — количество пикселей с уровнем серого  $i$ ,  $N$  — общее количество пикселей. Гистограмма показывает вероятность появления пикселей в одном оттенке серого на изображении. Из полученных значений можно рассчитать несколько параметров первого порядка, а именно:

- среднее значение

$$\mu = \sum_i i H_i, \quad (2)$$

- дисперсия

$$\sigma^2 = \sum_i (i - \mu)^2 H_i, \quad (3)$$

- асимметрия

$$\sum_i \left(\frac{i - \mu}{\sigma}\right)^3 H_i, \quad (4)$$

- эксцесс,

$$\sum_i \left(\frac{i - \mu}{\sigma}\right)^4 H_i, \quad (5)$$

- энтропия

$$-\sum_i H_i \log H_i. \quad (6)$$

Основное преимущество такого подхода — это его простота за счет использования стандартных дескрипторов для характеристики данных. Тем не менее, в некоторых задачах эффективность этого метода в обнаружении различий между уникальными текстурами ограничена, потому что метод не учитывает пространственные отношения и корреляцию между пикселями.

### 1.3 Полутоновая матрица смежности

Полутоновая матрица смежности (иногда матрица смежностей уровня серого — Gray Level Co-Occurrence Matrix, GLCM) — это матрица, которая показывает распределение уровня серого между соседними пикселями на изображении. Матрица строится по следующему алгоритму:

1. берется один пиксель изображения, для которого ищется строка матрицы со значением интенсивности этого пикселя;
2. берутся пиксели вокруг выбранного, ищется столбец с индексом интенсивности соседнего пикселя, к найденному элементу прибавляется 1;
3. алгоритм повторяется вплоть до полного перебора всех пикселей.

Размерность итоговой матрицы  $P$  совпадает с количеством уровней серого  $N$  оригинального изображения.

Такие матрицы представляют свойства текстуры изображения, но чувствительны к его масштабированию и повороту. Они не удобны для прямого применения при анализе медицинских изображений из-за большого размера; в связи с этим часто они лишь используются для вычисления различных метрик для более компактного представления текстур. В данном случае для каждого изображения извлекаются 14 характеристик, предложенных Р. Хараликом в 1973 г. [20] и используемых для задачи классификации текстур; среди них

- энергия

$$\sum_{i,j=1}^N p_{ij}^2, \quad (7)$$

- энтропия

$$\sum_{i,j=1}^N -p_{ij} \log p_{ij}, \quad (8)$$

- контраст,

$$\sum_{i,j=1}^N p_{ij}(i-j)^2, \quad (9)$$

- однородность

$$\sum_{i,j=1}^N p_{ij} \frac{1}{1+(i-j)^2}, \quad (10)$$

а также

- корреляция,
- дисперсия,
- обратный разностный момент,
- суммарные среднее, дисперсия и энтропия,
- информационные меры корреляции 1 и 2,
- максимальный коэффициент корреляции,
- дифференциальные дисперсия и энтропия,
- второй угловой момент.

## 1.4 Локальные бинарные шаблоны

Локальные бинарные шаблоны — это дескриптор с низкой вычислительной сложностью, предложенный Т. Ояла в 1996 г. для извлечения признаков текстуры [21]. Благодаря своей простоте и устойчивости к изменению

яркости и небольшим поворотам изображения данный метод является распространенным и эффективным способом в решении задач компьютерного зрения, в частности, распознавания лиц. Суть оригинального алгоритма локальных шаблонов заключается в кодировании пикселей с помощью сравнения их с данным пикселем (центральным) и создании таким образом двоичного числа. Для каждого центрального пикселя с координатами  $(x_c, y_c)$  и значением интенсивности  $g_c$  входного изображения его значение LBP оценивается путем сравнения значения  $g_c$  со значениями уровня серого пикселей на расстоянии  $R$  в пределах множества соседних пикселей  $P$ , обход по пикселям происходит либо по часовой, либо против часовой стрелки. Если значение интенсивности у центрального пикселя  $(x_c, y_c)$  выше, чем значение  $g_i$  у соседнего пикселя  $P_i$ , соседнему пикселю присваивается значение 0, в ином случае 1; в итоге получается  $P$ -битное двоичное число. Математически алгоритм определяется таким образом:

$$LBP^{P,R}(x_c, y_c) = \sum_{i=0}^P s(g_p^{P,R} - g_c)2^{i-1}, s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}. \quad (11)$$

В представленной системе для анализа изображений используются гистограммы распределения бинарных шаблонов, характеризующие частоту встречаемости того или иного шаблона; они и поступают на вход классификаторам.

## 1.5 Энергетические характеристики Лавса

Данный подход был предложен Лавсом для распознавания различных типов текстур в пределах одного окна. В этом методе для получения энергетических характеристик текстуры используются маски размера  $5 \times 5$ , полученные с помощью умножения друг на друга пяти векторов, каждый из которых

характеризует определенный признак текстуры:

$$\begin{aligned}L5 &= [1, 4, 6, 4, 1], \\E5 &= [-1, -2, 0, -2, -1], \\S5 &= [-1, 0, 2, 0, -1], \\R5 &= [1 - 4, 6, -4, 1],\end{aligned}\tag{12}$$

причем  $L5$  отвечает за получение симметричного взвешенного локального среднего значения,  $E5$  — за распознавание границ объекта,  $S5$  — за распознавание пятен,  $R5$  — за распознавание текстуры в виде ряби. Алгоритм получения характеристик Лавса:

1. по изображению перемещается небольшое окно и из каждого пикселя вычитается локальное среднее значение интенсивности (это нужно, чтобы уменьшить влияние интенсивности освещения на результаты);
2. к полученному изображению применяются все шестнадцать масок, получается шестнадцать новых изображений с фильтром;
3. для каждого изображения подсчитывается энергетический признак;
4. некоторые пары симметричных признаков комбинируются или усредняются, что дает устойчивость к повороту; итого получается шесть признаков [22].

Такой подход позволяет идентифицировать различные виды текстур, однако работает медленнее по сравнению с более простыми текстурными дескрипторами, описанными выше.

## 1.6 Моменты Цернике

Моменты Цернике — это проекция изображения на набор комплексных многочленов Цернике. Данные полиномы по своей природе ортогональны друг другу, и поэтому они могут представлять свойства изображения без избыточности информации. Алгоритм получения моментов Цернике состоит из трех шагов:

1. вычисляются радиальные многочлены;
2. рассчитываются базисные функции Цернике;
3. изображение проецируется на базисные функции и таким образом вычисляются моменты.

Действительный одномерный радиальный многочлен определяется таким образом:

$$R_{pq}(r) = \sum_{k=0}^{\frac{p-|q|}{2}} (-1)^k \frac{(p-k)!}{k! \left(\frac{p+|q|}{2} - k\right) \left(\frac{p-|q|}{2} - k\right)} r^{(p-2k)}, \quad (13)$$

где  $p$  — неотрицательное целое число, представляющее порядок радиального многочлена, а  $q$  — положительное или отрицательное целое число, удовлетворяющее следующим условиям:  $p \geq 0$ ,  $0 \leq q \leq p$  и  $p - |q|$  — четное число. Комплексные двумерные базисные функции Цернике в пределах единичного круга с использованием радиального полинома определяются как

$$V_{pq}(r, \theta) = R_{pq}(r) e^{-jq\theta}; j = \sqrt{-1}, |r| \leq 1. \quad (14)$$

Базисная функция Цернике удовлетворяет условию ортогональности:

$$\int_0^{2\pi} \int_0^1 V_{pq}^*(r, \theta) V_{nm}(r, \theta) r dr d\theta = \begin{cases} \frac{\pi}{p+1}, & \text{если } p = n, q = m \\ 0 & \text{в любом другом случае} \end{cases}. \quad (15)$$

Комплексные моменты Цернике порядка  $p$  окончательно определяются как

$$Z_{pq} = \frac{p+1}{\pi} \int_0^{2\pi} \int_0^1 f(r, \theta) V_{pq}^*(r, \theta) r dr d\theta; |r| \leq 1, \quad (16)$$

где  $f(r, \theta)$  — полярная форма функции изображения  $f(x, y)$ , а  $*$  обозначает комплексное сопряжение. Чтобы вычислить моменты Цернике из цифрового изображения, интегралы в уравнении заменяются суммированием, а координаты изображения нормализуются преобразованием отображения. Дискретная форма моментов Цернике для изображения размера  $N \times N$  выражается

следующим образом:

$$Z_{pq} = \frac{p+1}{\lambda_N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) V_{pq}^*(x, y), \quad (17)$$

$$Z_{pq} = \frac{p+1}{\lambda_N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) R_{pq}(x, y) e^{-jq\theta_{xy}}, \quad (18)$$

где  $0 \leq r_{xy} \leq 1$ , а нормировочный коэффициент  $\lambda_N$  - количество пикселей, расположенных в единичной окружности  $\pi$  в непрерывной области. Расстояние преобразования  $r_{xy}$  и фаза  $\theta_{xy}$  в пикселе с координатами  $(x, y)$  рассчитываются как

$$r_{xy} = \frac{\sqrt{(2x - N + 1)^2 + (2y - N + 1)^2}}{N}, \quad (19)$$

$$\theta_{xy} = \tan^{-1}\left(\frac{N - 1 - 2x}{2y - N + 1}\right). \quad (20)$$

Значение моментов Цернике сильно зависит от масштабирования и перемещения объектов, однако их величина не зависит от угла поворота. Поэтому величину момента Цернике можно использовать в качестве дескриптора для описания характеристик текстуры независимо от угла поворота аномалии на маммограмме. Моменты высоких порядков содержат больше информации о форме, но увеличивают затраты на их вычисление, поэтому в данной работе для каждого изображения извлекаются 24 момента (значение по умолчанию для функции zernikes moments в библиотеке Mahotas [23]).

## 1.7 Инвариантные моменты

Инвариантные моменты (представленные Ху в 1962 г. [24]) — это широко используемый в задачах компьютерного зрения дескриптор формы. В данной работе такие моменты используются для получения атрибутов, связанных с формой новообразования. Причина использования данного метода заключается в том, что он способен определять паттерн независимо от его масштаба и местоположения. Математически эти семь моментов можно описать как различные комбинации нормализованных центральных моментов  $\eta_{ij}$

второго и третьего порядка, полученных с помощью центральных моментов  $\mu_{ij}$  [25] ( $i$  и  $j$  – порядки центрального момента):

$$h_1 = \eta_{20} + \eta_{02}, \quad (21)$$

$$h_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2, \quad (22)$$

$$h_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2, \quad (23)$$

$$h_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2, \quad (24)$$

$$h_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\ + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2], \quad (25)$$

$$h_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + \\ + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}), \quad (26)$$

$$h_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] - \\ - (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]. \quad (27)$$

Доказано, что такие моменты инвариантны к вращению, масштабированию и переносу (первые шесть также нечувствительны к зеркальному отображению, знак последнего момента при таком отображении меняется на противоположный); при их построении центральный момент используется для устранения влияния переноса изображения, нормализация устраняет влияние масштабирования изображения, а полином строится для реализации инвариантных характеристик вращения. Моменты разного порядка отражают разные характеристики: так, моменты низкого порядка отвечают за основную форму объекта, а высокого — за сложные детали.

## Глава 2. Способы классификации изображений

### 2.1 Случайный лес

Случайный лес (Random Forest, RF) — это классификатор, который использует ансамбль решающих деревьев для принятия решений [4], [10]. Данный алгоритм использует бутстрэп-агрегирование (или бэггинг) для построения деревьев в ансамбле: если дано обучающее множество  $X$  с метками  $y$ , бэггинг итеративно выбирает случайную повторную подвыборку из обучающей выборки и обучает деревья под эту подвыборку. Итоговое решение классификатора принимается на основе голосования деревьев из ансамбля. Такой алгоритм классификации с помощью использования многих деревьев превосходит по точности простое решающее дерево. Случайный лес также преодолевает проблему переобучения, которая часто наблюдается в случае одного дерева.

### 2.2 AdaBoost

Алгоритм Adaptive Boosting (AdaBoost) представляет собой метод бустинга, который используется в качестве ансамблевого метода в машинном обучении [3], [4]. Суть алгоритма отражена в названии; каждый следующий ансамбль классификаторов (в данном случае в качестве классификаторов выбраны дефолтные в библиотеке `scikit-learn` [26] решающие деревья) строится по объектам, неверно классифицированным предыдущими ансамблями. Хотя данный алгоритм неустойчив к шуму в данных, он менее склонен к переобучению по сравнению с некоторыми другими классическими алгоритмами.

### 2.3 Метод k-ближайших соседей

Классификация методом шаблонов k-ближайших соседей (k-Nearest Neighbours, kNN) — один из самых ранних и простых алгоритмов классификации в машинном обучении. Этот алгоритм был впервые описан в начале 1950-х гг., но из-за своей трудоемкости при использовании больших обучающих множеств не был распространен до 1960-х годов, когда стали доступны высокие вычислительные мощности. С тех пор данный метод широко исполь-

зуется в области распознавания образов. Этот классификатор — также хорошо известный способ для детекции аномальных объектов на медицинских изображениях [17]. Несмотря на свою простоту, он может давать конкурентоспособные результаты в сравнении с более продвинутыми алгоритмами. Алгоритм kNN классифицирует неизвестный экземпляр в зависимости от того, к какому классу по большей части принадлежат его ближайшие соседи. Его производительность также в большой степени зависит от метрики расстояния, используемой для определения ближайших соседей. В данном случае в качестве метрики было выбрано евклидово расстояние [27].

## **2.4 Метод опорных векторов**

Метод опорных векторов является одним из самых простых и известных алгоритмов машинного обучения, который зарекомендовал себя как хороший классификатор в диагностике медицинских изображений [5], [8], [10], [13], [17]. Данный метод — это алгоритм обучения с учителем, основанный на концепции гиперплоскости, целью которого является разделение набора объектов на два класса. Он определяет некоторые опорные векторы из пространства признаков, которые помогают определить оптимальную гиперплоскость. Несмотря на то, что такой алгоритм разработан для использования в случае двух классов, его также можно применять и для нескольких классов, используя метод one-vs-rest, который заключается в разбиении исходной задачи на несколько задач бинарной классификации.

## **2.5 Многослойный перцептрон**

Многослойный перцептрон — широко используемый алгоритм в задаче распознавания образов [4], [14], [15]; это искусственная нейронная сеть с прямой связью, которая генерирует набор выходных данных из набора входных данных. MLP характеризуется различными слоями входных узлов, связанных как ориентированный граф между входным и выходным слоями. Данный классификатор использует алгоритм обратного распространения ошибки для обучения сети. Конфигурация нейронной сети, примененная в [4], показала достаточно высокие результаты; она же и использовалась в данном случае.

## Глава 3. Описание экспериментов

### 3.1 Архитектура системы

После изучения и анализа методов извлечения признаков становится понятно, что каждый метод имеет свои преимущества и недостатки (например, текстурные методы чувствительны к масштабированию и повороту — это недостаток, который методы извлечения моментов не имеют). Для использования преимуществ каждого метода предложена архитектура системы, представленная на Рисунке 5.

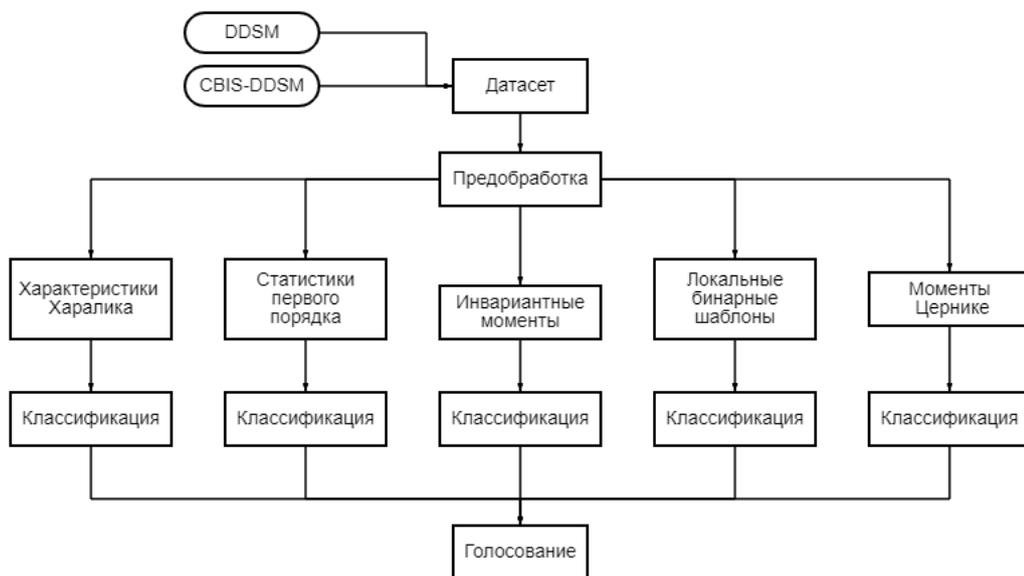


Рис. 5: Архитектура системы

### 3.2 Инструментарий

Для реализации предложенной архитектуры был выбран язык программирования Python благодаря простоте использования, а также наличию множества открытых библиотек для решения задач анализа данных и обработки изображений. Были выбраны следующие библиотеки:

- OpenCV [28], Mahotas [23] и Scikit-image [29] — популярные открытые библиотеки для задач компьютерного зрения и обработки изображений;

- PyFeats [22] — библиотека с открытым исходным кодом, содержащая реализацию многих методов извлечения признаков из изображений;
- Pandas [30] — открытая высокоуровневая библиотека, обеспечивающая высокую производительность для анализа и обработки данных;
- Scikit-learn [26] — открытая библиотека машинного обучения для Python, включающая в себя многие алгоритмы классификации, в том числе перечисленные в предыдущей главе;
- NumPy — основной пакет для научных вычислений на Python.

Для обработки датасета и проведения экспериментов с классификацией был использован сервис Google Colaboratory.

### 3.3 Эксперименты

В качестве экспериментов было принято решение использовать оба набора меток из датасета: 0–1 для бинарной и 0–1–2–3–4 для мультиклассовой классификации. В первую очередь были использованы метки 0–1; для детекции аномалий на маммограммах для каждого изображения из датасета были извлечены векторы признаков, описанных выше, после чего набор векторов признаков подавался на вход классификаторам. Наборы признаков и меток были поделены на обучающее и тестовое множество; на обучающее пришлось 80% всех данных, на тестовое – 20%. Эффективность каждой комбинации оценивалась с помощью показателя точности — отношения количества правильно классифицированных объектов к общему количеству объектов. Результаты работы каждого метода с каждым классификатором для детекции аномалий представлены в Таблице 1.

**Таблица 1:** Точность всех комбинаций методов и классификаторов для бинарной классификации, в %

	AdaBoost	RF	SVM	MLP	kNN
Har feat.	82,9	<b>85,5</b>	80,2	78,5	79,6
LBP	85,5	85,6	<b>86,4</b>	83,2	83,8

Hu	79,2	<b>80,4</b>	76,9	77,2	75,4
Law	83,1	<b>83,5</b>	77,9	76,9	79,6
Zernike	74,5	<b>77,0</b>	76,9	76,9	69,1
FOS	81,6	<b>83,1</b>	80,6	81,4	77,6

Помимо точности, для оценки работы комбинаций методов и классификаторов использовались еще и показатели чувствительности и специфичности. Пусть  $TP$  и  $TN$  — число правильно классифицированных аномалий и правильно классифицированных здоровых объектов, а  $FP$  и  $FN$  — число ложноположительных и ложноотрицательных результатов соответственно, тогда для случая бинарной классификации эти показатели можно представить так:

$$sensitivity = \frac{TP}{TP + FN}, \quad (28)$$

$$specificity = \frac{TN}{TN + FP}$$

Показатели точности, чувствительности и специфичности для пяти комбинаций, показавших наилучшую точность, представлены в Таблице 2.

**Таблица 2:** Точность, чувствительность и специфичность некоторых комбинаций для бинарной классификации, в %

	Точность	Чувств.	Специф.
Har feat. + RF	85,5	91,4	65,9
LBP + SVM	86,4	95,4	56,1
Hu + RF	80,4	90,3	48,3
Law + RF	83,5	92,3	54,3
FOS + RF	83,1	92,0	62,4

Среди этих методов и классификаторов было проведено голосование на тестовом множестве: лучшие результаты были получены, когда решение основывалось на более чем двух голосах; были достигнуты точность 86,8%, чувствительность 89,6% и специфичность 77,2%.

На втором этапе экспериментов использовались метки 0–1–2–3–4 (нет аномалий, доброкачественная кальцификация, доброкачественная опухоль, злокачественная кальцификация, злокачественная опухоль); показатели точности для этого случая представлены в Таблице 3.

**Таблица 3:** Точности всех комбинаций методов и классификаторов для мультиклассовой классификации, в %

	AdaBoost	RF	SVM	MLP	kNN
Har feat.	75,8	<b>80,6</b>	76,9	80,5	75,6
LBP	76,1	78,9	<b>80,0</b>	79,1	77,3
Hu	73,3	<b>77,6</b>	76,7	76,7	75,6
Law	73,7	<b>78,6</b>	77,9	77,5	76,9
Zernike	71,1	<b>76,9</b>	74,1	76,8	76,2
FOS	73,4	<b>77,5</b>	76,0	75,9	74,2

Для трех комбинаций, давших самую высокую точность классификации, также были оценены параметры чувствительности и специфичности (в случае мультиклассовой классификации эти параметры можно оценить для каждого класса отдельно); показатели представлены в Таблице 4.

**Таблица 4:** Чувствительность (сверху) и специфичность (снизу) некоторых комбинаций для мультиклассовой классификации, в %

	0	1	2	3	4
Har feat. + RF	54,4,	98,2,	98,2,	98,8,	97,0,
	98,1	53,5	46,6	45,0	43,3
LBP + SVM	69,4,	95,5,	96,2,	97,9,	96,4,
	97,5	42,9	34,9	41,0	39,3
Law + RF	45,4,	97,7,	98,4,	99,0,	97,8,
	96,5	44,7	36,0	43,5	39,6

Для этих же комбинаций было проведено голосование, где решение принималось на основе двух или более голосов, как и в предыдущем случае. Итоговые показатели представлены в Таблице 5.

**Таблица 5:** Чувствительность и специфичность после голосования для мультиклассовой классификации, в %

	0	1	2	3	4
Чувствительность	47,5	99,3	98,5	99,3	97,9
Специфичность	99,0	43,5	41,3	45,5	40,0

## Глава 4. Анализ результатов

В случае бинарной классификации многие сочетания методов и классификаторов показали хорошие результаты — больше 80% точности. Из методов экстракции признаков лучшие результаты показали характеристики Харалика и локальные бинарные шаблоны, худшие результаты — метод моментов Цернике, предположительно, из-за шума и нечетких объектов на изображении (было показано, что на уже сегментированном изображении аномалии метод дает достаточно высокую точность). Из классификаторов лучшие результаты показали Random Forest и AdaBoost, алгоритмы ансамблевого обучения, худшие — метод k-ближайших соседей, самый простой из представленных.

Проанализировав Таблицу 2, можно заметить, что чувствительность для всех комбинаций достаточно высокая, но специфичность снижена; это значит, что присутствует высокий риск ложноположительного диагноза. Голосование было введено в качестве попытки увеличить специфичность и сбалансировать показатели системы. В итоге голосование, где решение принималось на основе половины или более голосов, слегка увеличило точность и уменьшило чувствительность, однако специфичность значительно увеличилась. Изменение показателей для бинарной классификации представлено на Рисунке 6.

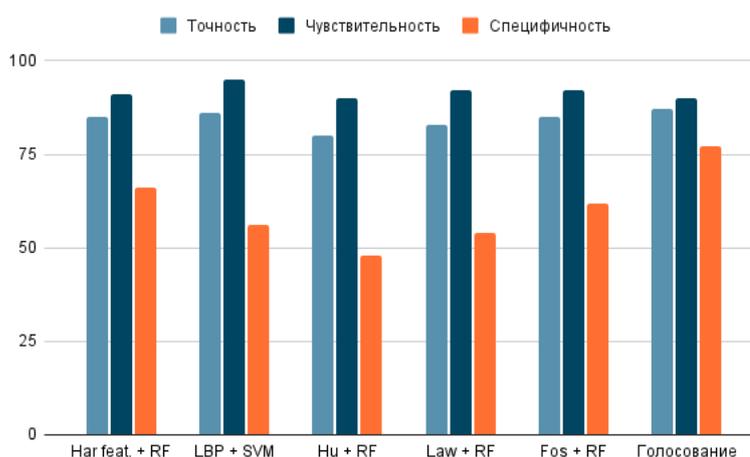


Рис. 6: Показатели работы системы для бинарной классификации

Для случая мультиклассовой классификации точность работы системы

снизилась по сравнению с бинарной классификацией (что ожидаемо, так как определить опухоль или кальцификацию — более сложная задача, чем просто отличить здоровый объект от больного). Снова был высок уровень ложноположительных результатов (см. Таблицу 4). Голосование в данном случае незначительно увеличило точность, тем не менее, специфичность осталась такой же низкой. В связи с такими результатами экспериментов в итоговый вариант системы была включена детекция аномалий именно с помощью меток 0–1.

## Заключение

В результате проведенной работы разработана система, решающая задачу детекции аномалии на маммографических изображениях. Проведен поиск и анализ литературы на тему уже существующих решений поставленной и похожих задач и изучено современное состояние вопроса. Изучены методы извлечения текстурных признаков и моментов из изображения для повышения точности классификации; проведены эксперименты с разными комбинациями дескрипторов и алгоритмов машинного обучения. Показатели итогового варианта системы в основном сопоставимы с другими решениями задачи, использующими классическое машинное обучение, хотя уступают некоторым продвинутым реализациям. Тем не менее, благодаря сочетанию нескольких методов в голосовании, полученные результаты будут устойчивы к потенциальному изменению или ухудшению качества набора входных данных. Также итоговая точность метода сопоставима с моделями, использующими глубокое обучение [31], [32], но представленная система имеет преимущество в виде отсутствия необходимости долгого времени на обучение и высоких вычислительных мощностей. Сравнение с некоторыми решениями представлено в Таблице 6.

**Таблица 6:** Сравнение с некоторыми существующими решениями

Авторы	Метод	Классиф.	Датасет	Точность
Матос и др. [3]	SIFT-LBP	AdaBoost	DDSM	99%
Роча и др. [7]	GLCM + Gleason Index	SVM	DDSM	86%
Фархан и др. [11]	LBP	Logistic regression	MIAS	85%
Алоби и др. [17]	FOS	Voting	DDSM	87%
Дезерно и др. [12]	2DPCA	SVM	IRMA	80%
Цохацидис и др [31].	Fine-tuning	ResNet152	CBIS-DDSM	75%

Ванг и др. [32]	Domain adaptation	ResNet34	CBIS-DDSM	85%
Предложенный метод	GLCM, FOS, LBP, Law's, Hu	Voting	DDSM	86%

Более того, учитывая то, что при изучении маммограм радиологами пропускаются от 10 до 30% случаев рака и до сих пор высок уровень и ложноположительных, и ложноотрицательных результатов [2], точность итогового варианта системы сопоставима или превышает точность нынешней медицинской диагностики, а значит, вполне может использоваться как средство поддержки решений врача-онколога. Среди возможных вариантов улучшения работы системы можно перечислить смену датасета на новый, состоящий из цифровых маммограм, а не отсканированных, а также добавление сегментирования изображения для более точной детекции аномалии в помощь специалисту-маммологу.

## Список использованных источников

- [1] Рак молочной железы // ВОЗ. URL: <https://www.who.int/ru/news-room/fact-sheets/detail/breast-cancer> (дата обращения: 11.05.2022).
- [2] Меских Е.В., Оксанчук Е.А., Солодкий В.А. Рак молочной железы: диагностические сложности и ошибки // Вестник РНЦРР. 2020. №2. — URL: <https://cyberleninka.ru/article/n/rak-molochnoy-zhelezy-diagnosticheskie-slozhnosti-i-oshibki> (дата обращения: 10.05.2022).
- [3] Matos, C,E Diagnosis of breast tissue in mammography images based local feature descriptors / C,E Matos, J. C. Souza, J,O Diniz // Multimedia Tools and Applications. — 2019. — № 78. — С. 12961–12986. — URL: <https://link.springer.com/article/10.1007/s11042-018-6390-x> (дата обращения: 10.05.2022).
- [4] Computer Aided Breast Cancer Detection Using Ensembling of Texture and Statistical Image Features / S. Roy, S. Das, D. Kar [и др.] // Sensors. — 2021. — № 21. — С. 3628. — URL: <https://www.mdpi.com/1424-8220/21/11/3628> (дата обращения: 10.05.2022).
- [5] Phadke, A. Fusion of local and global features for classification of abnormality in mammograms / A. Phadke, P. Rege // Sādhanā. — 2016. — Т. 41. — С. 1-11. — URL: [https://www.academia.edu/50779923/Fusion\\_of\\_local\\_and\\_global\\_features\\_for\\_classification\\_of\\_abnormality\\_in\\_mammograms](https://www.academia.edu/50779923/Fusion_of_local_and_global_features_for_classification_of_abnormality_in_mammograms) (дата обращения: 11.05.2022).
- [6] Effective Extraction of Gabor Features for False Positive Reduction and Mass Classification in Mammography / M. Hussain, S. Khan, G. Muhammad [и др.] // Applied Mathematics & Information Sciences. — 2014. — Т. 8 — № 1. — С. 397-412. — URL: <https://www.naturalspublishing.com/Article.asp?ArtcID=5226> (дата обращения: 11.05.2022).

- [7] Texture analysis of masses in digitized mammograms using Gleason and Menhinick Diversity Indexes / S. Rocha, G. Junior, A. Silva, A. Paiva // Revista Brasileira de Engenharia Biomédica. — 2014. — Т. 30. — С. 35-46. — URL: [https://www.researchgate.net/publication/276007723\\_Texture\\_analysis\\_of\\_masses\\_in\\_digitized\\_mammograms\\_using\\_Gleason\\_and\\_Menhinick\\_Diversity\\_Indexes](https://www.researchgate.net/publication/276007723_Texture_analysis_of_masses_in_digitized_mammograms_using_Gleason_and_Menhinick_Diversity_Indexes) (дата обращения: 12.05.2022).
- [8] Sharma, S. Computer-aided diagnosis of malignant mammograms using Zernike moments and SVM / S. Sharma, P. Khanna // Journal of digital imaging. — 2014. — Т. 28. — URL: <https://pubmed.ncbi.nlm.nih.gov/25005867/> (дата обращения: 11.05.2022).
- [9] Mammogram Classification Using Selected GLCM Features and Random Forest Classifier / V. P. Singh, A. Srivastava, D. Kulshreshtha [и др.] // International Journal of Computer Science and Information Security (IJCSIS). — 2016. — Т. 14 — № 6. — URL: [https://www.academia.edu/27067717/Mammogram\\_Classification\\_Using\\_Selected\\_GLCM\\_Features\\_and\\_Random\\_Forest\\_Classifier](https://www.academia.edu/27067717/Mammogram_Classification_Using_Selected_GLCM_Features_and_Random_Forest_Classifier) (дата обращения: 11.05.2022).
- [10] Vijaya, M. M. Gabor Filter Based Classification of Mammography Images Using LS-SVM and Random Forest Classifier / M. M. Vijaya, B. T. Christy // International Conference on Recent Trends in Image Processing and Pattern Recognition. — Singapore : Springer, 2019. — С. 69-83. — URL: [https://link.springer.com/chapter/10.1007/978-981-13-9184-2\\_6](https://link.springer.com/chapter/10.1007/978-981-13-9184-2_6) (дата обращения: 11.05.2022).
- [11] Farhan, A. Texture Analysis of Mammogram Using Local Binary Pattern Method / A. Farhan, Kamil Y // Journal of Physics: Conference Series. — 2020. — Т. 1530. — URL: [https://www.researchgate.net/publication/341679511\\_Texture\\_Analysis\\_of\\_Mammogram\\_Using\\_Local\\_Binary\\_Pattern\\_Method](https://www.researchgate.net/publication/341679511_Texture_Analysis_of_Mammogram_Using_Local_Binary_Pattern_Method) (дата обращения: 20.05.2022).
- [12] Computer-aided diagnostics of screening mammography using content-based image retrieval / T. Deserno, M. Soiron, J. Oliveira // Proceedings

- of SPIE - The International Society for Optical Engineering. — 2012. — Т. 8315. — С. 527-831. — URL: [https://www.researchgate.net/publication/228438050\\_Computer-aided\\_diagnostics\\_of\\_screening\\_mammography\\_using\\_content-based\\_image\\_retrieval](https://www.researchgate.net/publication/228438050_Computer-aided_diagnostics_of_screening_mammography_using_content-based_image_retrieval) (дата обращения: 19.05.2022).
- [13] Breast Cancer Histopathological Images Recognition Based on Low Dimensional Three-Channel Features / Y. Hao, S. Qiao, L. Zhang [и др.] // *Frontiers in Oncology*. — 2021. — Т. 11. — URL: [https://www.researchgate.net/publication/352375311\\_Breast\\_Cancer\\_Histopathological\\_Images\\_Recognition\\_Based\\_on\\_Low\\_Dimensional\\_Three-Channel\\_Features](https://www.researchgate.net/publication/352375311_Breast_Cancer_Histopathological_Images_Recognition_Based_on_Low_Dimensional_Three-Channel_Features) (дата обращения: 20.05.2022)
- [14] Selection Mammogram Texture Descriptors Based on Statistics Properties Backpropagation Structure / S. Uyun, S. Hartati, A. Harjoko, S. S. Seno // *Journal of Computer Science (IJCSIS)*. — 2013. — Т. 11 — № 5. — URL: [https://www.researchgate.net/publication/251567122\\_Selection\\_Mammogram\\_Texture\\_Descriptors\\_Based\\_on\\_Statistics\\_Properties\\_Backpropagation\\_Structure](https://www.researchgate.net/publication/251567122_Selection_Mammogram_Texture_Descriptors_Based_on_Statistics_Properties_Backpropagation_Structure) (дата обращения: 20.05.2022).
- [15] Abdalla, A. M. Detection of Masses in Digital Mammogram Using Second Order Statistics and Artificial Neural Network / A. M. Abdalla, S. Dress, N. Zaki // *International Journal of Computer Science & Information Technology*. — 2011. — Т. 3. — С. 176-186. — URL: [https://www.researchgate.net/publication/215644411\\_Detection\\_of\\_Masses\\_in\\_Digital\\_Mammogram\\_Using\\_Second\\_Order\\_Statistics\\_and\\_Artificial\\_Neural\\_Network](https://www.researchgate.net/publication/215644411_Detection_of_Masses_in_Digital_Mammogram_Using_Second_Order_Statistics_and_Artificial_Neural_Network) (дата обращения: 15.05.2022).
- [16] Benign and malignant breast tumors classification based on region growing and CNN segmentation / R. Rouhi, M. Jafari, S. Kasaei, P. Keshavarzian // *International Journal of Computer Science & Information Technology*. — 2015. — Т. 42. — С. 990–1002. — URL: [https://www.academia.edu/26949502/Benign\\_and\\_malignant\\_breast\\_tumors\\_classification\\_](https://www.academia.edu/26949502/Benign_and_malignant_breast_tumors_classification_)

based\_on\_region\_growing\_and\_CNN\_segmentation (дата обращения: 11.05.2022).

- [17] Alhaj, A. M. Multi-classifier method based on voting technique for mammogram image classification / A. M. Alhaj, A. Ahmed, A. O. Ibrahim // Journal of software engineering & intelligent systems. — 2017. — Т. 2(3). — С. 280-285. — URL <http://repository.ush.sd:8080/xmlui/handle/123456789/465> (дата обращения: 19.05.2022).
- [18] Scuccimarra, E. DDSM Mammography / E. Scuccimarra // Kaggle : [сайт]. — URL: <https://www.kaggle.com/datasets/skooch/ddsm-mammography> (дата обращения: 10.05.2022).
- [19] Lateef, R. Contrast Enhancement of the Mammographic Image Using Retinex with CLAHE methods / R. Lateef // Iraqi Journal of Science. — 2017. — Т. 58. — № 1. — С. 327-336. — URL: [https://www.researchgate.net/publication/334001227\\_Contrast\\_Enhancement\\_of\\_the\\_Mammographic\\_Image\\_Using\\_Retinex\\_with\\_CLAHE\\_methods](https://www.researchgate.net/publication/334001227_Contrast_Enhancement_of_the_Mammographic_Image_Using_Retinex_with_CLAHE_methods) (дата обращения: 19.05.2022).
- [20] Haralick R.M., Shanmugam K., Dinstein I. Textural Features for Image Classification // IEEE Transactions on Systems, Man, and Cybernetics. 1973. Vol. SMC-3, No. 6, pp. 610-621. Haralick, R. Textural Features for Image Classification / R. Haralick, K. Shanmugam, I. Dinstein // IEEE Transactions on Systems, Man and Cybernetics. — 1973. — Т. SMC-3. — № 6 — С. 610-621. — URL: [https://www.researchgate.net/publication/302341151\\_Textural\\_Features\\_for\\_Image\\_Classification](https://www.researchgate.net/publication/302341151_Textural_Features_for_Image_Classification) (дата обращения: 19.05.2022).
- [21] Ojala, T. A comparative study of texture measures with classification based on featured distributions / T. Ojala, M. Pietikäinen, D. Harwood // Pattern Recognition. — 1996. — Т. 26(1). — С. 51-59. — URL: <https://www.sciencedirect.com/science/article/abs/pii/0031320395000674> (дата обращения: 20.05.2022).

- [22] pyfeats 1.0.0 // PyPI : [сайт]. — URL: <https://pypi.org/project/pyfeats/> (дата обращения: 19.05.2022).
- [23] Mahotas: Computer Vision in Python // Mahotas : [сайт]. — URL: <https://mahotas.readthedocs.io/en/latest/> (дата обращения: 19.05.2022).
- [24] Hu, M. K. Visual pattern recognition by moment invariants / M. K. Hu // IRE Transactions on Information Theory. — 1992. — Т. 8 — № 2. — С. 179-187. <https://ieeexplore.ieee.org/document/1057692> (дата обращения: 20.05.2022).
- [25] Huang, Z. Analysis of Hu's moment invariants on image scaling and rotation / Z. Huang, J. Leng // Proc. of 2nd International Conference on Computer Engineering and Technology (ICCET). — 2010. — Т. 7. — С. 476-480. — URL: [https://www.researchgate.net/publication/224146066\\_Analysis\\_of\\_Hu's\\_moment\\_invariants\\_on\\_image\\_scaling\\_and\\_rotation](https://www.researchgate.net/publication/224146066_Analysis_of_Hu's_moment_invariants_on_image_scaling_and_rotation) (дата обращения: 22.05.2022).
- [26] scikit-learn: Machine Learning in Python // scikit-learn : [сайт]. — URL: <https://scikit-learn.org/stable/> (дата обращения: 22.05.2022).
- [27] Nusantara, A. Classification of Digital Mammogram based on Nearest-Neighbor Method for Breast Cancer Detection / A. Nusantara, E. Purwanti, S. Soelistono // International Journal of Technology. — 2016. — Т. 7. — С. 71-77. — URL: [https://www.researchgate.net/publication/292385797\\_Classification\\_of\\_Digital\\_Mammogram\\_based\\_on\\_Nearest-Neighbor\\_Method\\_for\\_Breast\\_Cancer\\_Detection](https://www.researchgate.net/publication/292385797_Classification_of_Digital_Mammogram_based_on_Nearest-Neighbor_Method_for_Breast_Cancer_Detection) (дата обращения: 19.05.2022).
- [28] OpenCV // OpenCV : [сайт]. — URL: <https://opencv.org/> (дата обращения: 23.05.2022).
- [29] scikit-image: image processing in python // scikit-image : [сайт]. — URL: <https://scikit-image.org/> (дата обращения: 23.05.2022).
- [30] pandas - Python Data Analysis Library // pandas : [сайт]. — URL: <https://pandas.pydata.org/> (дата обращения: 23.05.2022).

- [31] Tsochatzidis, L. Deep learning for breast cancer diagnosis from mammograms—A comparative study / L. Tsochatzidis, C. Lena, P. Ioannis // Journal of imaging. — 2019. — Т. 5(3). — № 37. — URL: <https://pubmed.ncbi.nlm.nih.gov/34460465/> (дата обращения: 19.05.2022).
- [32] Deep adversarial domain adaptation for breast cancer screening from mammograms / Y. Wang, Y. Feng, L. Zhang [и др.] // Medical image analysis. — 2021. — № 73. — URL: <https://pubmed.ncbi.nlm.nih.gov/34246849/> (дата обращения: 19.05.2022).