

Классификация патологий молочной железы с использованием глубокой сверточной нейронной сети и трансферного обучения

А.Н. Ручай^{*,***}, В.И. Кобер^{**}, К.А. Дорофеев^{*}, В.Н. Карнаухов^{**}, М.Г. Мозеров^{**}

^{*} Челябинский государственный университет, Челябинск, Россия

^{**} Институт проблем передачи информации, Российская академия наук, Москва, Россия

^{***} Южно-Уральский государственный университет (национальный исследовательский университет), Челябинск, Россия

Поступила в редколлегию 11.11.2020

Аннотация—Предложен новый алгоритм классификации патологий молочной железы в цифровой маммографии с использованием сверточной нейронной сети и трансферного обучения. За основу были выбраны следующие предобученные нейронные сети: MobileNetV2, InceptionResNetV2, Xception и ResNetV2. Для повышения надежности классификации все маммографические изображения были предварительно обработаны. Было проведено трансферное обучение с использованием методов аугментации данных и тонкой настройки нейронной сети. В статье обсуждается точность предложенного алгоритма классификации патологий молочной железы на реальных данных и сравнивается с точностью известных алгоритмов классификации патологий на открытой базе данных MIAS.

КЛЮЧЕВЫЕ СЛОВА: классификация патологий, цифровая маммография, глубокая сверточная нейронная сеть, трансферное обучение, аугментация данных, тонкая настройка сети.

ВВЕДЕНИЕ

Рак молочной железы — это наиболее распространенный вид рака и одна из основных причин смерти женщин во всем мире [1,2,3]. Раннее выявление патологий и правильное лечение увеличивают вероятность излечения, и, как следствие, продолжительность жизни пациентов. Несмотря на то, что существуют различные методы выявления рака молочной железы, такие как магнитно-резонансная томография, ультразвук, рентгеновская маммография продолжает оставаться наиболее широко используемым методом раннего выявления патологий молочной железы [4,5].

На качество визуального анализа медицинских изображений существенно влияет “человеческий фактор”. Так визуальная диагностика рака молочной железы по рентгеновским маммограммам имеет ложно-отрицательный (пропущенный рак) уровень более 16%, что связано с плотной тканью молочной железы, скрывающей рак, со зрительными ограничениями человека и с наличием шума на изображениях [6]. Чтобы облегчить задачу врачей по выявлению патологий молочной железы на ранних стадиях, активно разрабатываются методы и алгоритмы компьютерных систем диагностики (CAD). Общий подход к созданию таких систем заключается в выборе и вычислении характеристик объектов интереса на исходных снимках с последующим выбором модели для их классификации [7]. Фактически, типичная CAD состоит из следующих последовательных этапов [8,9]: этап предварительной обработки, который используется для улучшения качества изображения, удаление шума и маркеров на маммограмме; этап сегментации областей интереса, который используется для выделения областей, содержащих патологии; извлечение текстуры, статистических и геометрических характеристик; этап

классификации, на котором предварительно обученный классификатор используется для выявления и классификации патологий в ткани груди.

Однако, несмотря на большие возможности выбора признаков и классификаторов, нелинейные функции принятия решений до сих пор не используются при создании САД. Недавно была предложена система для диагностики рака молочной железы [9], основанная на вейвлет-преобразовании контура для получения особенностей в области интереса. Чтобы уменьшить размер признаков, используется гибридный подход для выбора признаков, в котором генетический алгоритм и машина опорных векторов объединены для обнаружения и классификации патологий. Стоит отметить, что в обычных САД используются в основном линейные методы обработки [10, 11]. Кроме того, в подобных системах используются: метод главных компонент для уменьшения размерности пространства признаков, вейвлет-преобразования — это интегральное преобразования, смесь гауссовых распределений, состоящее из ограниченного числа гауссовых функций. В САД [12, 13, 14] часто используется машинное обучение, а методы показывают хорошую точность (80–90%), что, однако, недостаточно для эффективного поиска патологий молочной железы. Кроме того, уровень ложно-положительных ошибок в предложенных системах очень высок, и научное сообщество уделяет больше внимания разработке методов снижения этого показателя [15].

В последние годы был достигнут значительный прогресс в сложных задачах распознавания изображений благодаря использованию глубоких нейронных сетей с тремя или более слоями, которые сочетают в себе как выбор и вычисление признаков, так и классификацию, тем самым напрямую создавая итоговую функцию принятия решений [16]. Очевидно, что если использовать больше слоев в таких сетях, то можно создать более сложные нелинейные функции. Более того, глубокое обучение имеет преимущество перед традиционными методами машинного обучения благодаря своему характеру обучения: большее количество данных в обучающей выборке приводит к более точной классификации [17, 18]. Точность алгоритмов машинного обучения при классификации слабо различимых классов в какой-то момент перестает расти, несмотря на увеличение обучающей выборки, в то время как точность методов глубокого обучения в аналогичных условиях монотонно возрастает.

Целью этой статьи является разработка нового алгоритма классификации патологий молочной железы в цифровой маммографии на основе сверточной нейронной сети (CNN) с использованием подхода трансферного обучения. В данном подходе выполняется дообучение части большой предобученной нейронной сети, решающей похожую задачу классификации с большим объемом обучающих данных. Были выбраны следующие предобученные нейронные сети: MobileNetV2, InceptionResNetV2, Xception и ResNetV2 для разработки нового алгоритма классификации патологий в цифровой маммографии на основе сверточной нейронной сети. Результаты обучения сравниваются с результатами классификации, полученными с предобученными сетями: MobileNet, NasNet, InceptionV3, ResNet50 [19].

Статья организована следующим образом. В разделе 2 дается обзор работ по данной тематике. В разделе 3 представлены предлагаемые подходы к классификации патологий молочной железы на основе глубокой сверточной нейронной сети. В разделе 4 описаны результаты компьютерного моделирования с точки зрения точности классификации патологий. Наконец, в разделе 5 представлены наши выводы.

1. ОБЗОР АЛГОРИТМОВ КЛАССИФИКАЦИИ ПАТОЛОГИЙ МОЛОЧНОЙ ЖЕЛЕЗЫ

Используя алгоритмы обработки изображений и современные компьютерные технологии, можно значительно повысить информативность визуальных данных в различных системах лучевой диагностики. Современные алгоритмы обработки изображений обеспечивают: улучшение визуализации патологического образования (увеличение контрастности, удаление с изоб-

ражения “лишних” областей или маркеров, краев и т.д.); определение относительной плотности тканей подозрительных образований по отношению к плотности окружающих тканей, включая плотность краев; определение однородности области интереса по плотности; оценка количественных характеристик. Это позволяет значительно повысить информативность рентгеновского снимка, при этом превосходя возможности других, более современных и более дорогих методов.

С другой стороны, это может привести к повышению объективности диагностики и автоматизации процесса распознавания образований. Учитывая относительно низкую стоимость и высокую распространенность систем рентгеновской диагностики, алгоритмы автоматической обработки рентгенограмм в медицинской практике очень эффективны. Для повышения надежности диагностики по изображениям при разработке такой системы требуется реализация метода распознавания образов. В настоящее время интенсивно разрабатываются интеллектуальные системы для описания формы анализируемых изображений или для извлечения из них метрической или семантической информации. Анализ семантики — это вершина иерархической процедуры обработки изображений, сложность которой связана с тем, что изначально эта процедура решает некорректную задачу.

В последние годы многие научные группы по всему миру занимаются разработкой новых и модификацией существующих компьютерных методов ранней диагностики рака на основе анализа медицинских изображений. Основные усилия исследователей направлены на улучшение процесса выявления патологий за счет расширения пространства атрибутов для выбранных областей интереса, предположительно являющихся патологиями, повышения точности вычисления значений признаков в областях интереса, а также применение самых современных и эффективных моделей классификации патологий, характерных для определенных заболеваний.

При построении интеллектуальных систем медицинской диагностики часто используются сверточные нейронные сети (CNN). CNN — это специальные нейронные сети, которые способны дублировать возможности человеческого интеллекта в области обработки изображений, используя вычислительную мощность компьютеров, и при обработке больших объемов информации учатся на аннотированных визуальных примерах. Есть два подхода к использованию CNN для интерпретации рентгеновских изображений. Первый подход состоит в том, чтобы извлечь вектор информативных признаков из изображения или на уже выделенной области интереса, а затем построить модель классификации с учетом вектора информативных признаков. Второй подход предполагает применение классификатора непосредственно к данным изображения или на уже выделенной области интереса. Первый подход можно назвать попиксельной классификацией. Это означает, что классификация осуществляется путем присвоения каждому пикселю изображения определенного класса. Как правило, это двоичная классификация. В качестве примера такой классификации рассмотрим автоматизированную систему обнаружения микрокальцинатов на цифровых маммограммах [20]. Метод классификации состоит из четырех этапов: предварительная обработка изображения; сегментация или выделение областей интереса на изображении; выбор информативных признаков, методы выделения которых основаны на анализе текстурных, спектральных, статистических и геометрических характеристик сегмента; классификации, которая предусматривает построение классификаторов с использованием нейронных сетей, машины опорных векторов, метод k -ближайших соседей и т.д.

Сегодня существует множество алгоритмов обработки маммографических изображений для улучшения визуального качества маммограмм [21], но этого недостаточно для выявления патологий при скрининговом исследовании. Алгоритмы [5] позволяют выделить границы опухоли на основе характеристик текстуры, таких как энергия, энтропия, стандартное отклонение и т.д. Недостатком таких алгоритмов является хранение большого количества эталонных харак-

теристик для сравнения. Также существуют алгоритмы выделения онкологических областей с микрокальцинатами [22]. Этот метод диагностики имеет ряд недостатков: во-первых, некоторые артефакты на маммограмме могут быть ошибочно приняты за кальцинаты, что является ошибкой при диагностике, во-вторых, у 70% онкологических больных микрокальцинаты отсутствуют. Большинство разработанных алгоритмов, основанных на ортогональных преобразованиях [23, 24, 25], могут быть использованы для устранения помех на маммографических изображениях, а также для повышения их качества.

В работе [26] предложен двухэтапный метод сегментации и классификации опухоли молочной железы, который сначала сегментирует опухоль молочной железы в области интереса с использованием генеративной состязательной сети (GAN), а затем классифицирует ее бинарную маску с использованием дескриптора формы на основе CNN. Результаты сегментации показывают важность использования GAN сети для оптимизации. Более высокая производительность, полученная с помощью метода [26], подтверждает идею о том, что при использовании CNN можно надежно распознавать форму опухоли только на основе морфологической информации.

В работе [19] сравнивались модели InceptionV3, Resnet50, MobileNet и NasNet, предварительно обученные для задачи классификации аномалий маммографии. По результатам был сделан вывод о возможности использования подхода трансферного обучения из задачи распознавания произвольных изображений для классификации маммографических изображений. Однако эффективность построенного классификатора также зависит от предварительной обработки изображений. Resnet50 — это модель, которая достигла наилучшей точности для набора данных CBIS-DDSM с точностью 78,4% [19].

2. КЛАССИФИКАЦИИ ПАТОЛОГИЙ МОЛОЧНОЙ ЖЕЛЕЗЫ С ИСПОЛЬЗОВАНИЕМ ГЛУБОКОЙ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

В настоящее время для реализации одного из ключевых этапов компьютерной диагностики, связанного с классификацией патологий, часто используется CNN, как одна из наиболее эффективных моделей распознавания объектов на изображении. Однако сложность применения данной модели заключается в отсутствии формализованного подхода к формированию архитектуры CNN. В существующих системах подробно рассматривается выбор наиболее эффективных параметров архитектуры CNN, которые могут существенно повлиять на точность классификации, но качество всей диагностической системы до сих пор не учитывался. Рассмотрение именно этой проблемы является основным в данной работе. Главная задача построения архитектуры CNN — уменьшить размер входного изображения до трехмерных слоев с размерами 1×1 , 2×2 , 3×3 таким образом, чтобы получить выходные сигналы в виде вероятности того, что входное изображение принадлежит к одному из представленных классов. Архитектура CNN разделена на несколько слоев с определенными значениями характеристик, чередование которых позволяет создать наиболее эффективную архитектуру CNN. При проектировании архитектуры CNN увеличение количества слоев и связей в сети позволяет строить более сложные модели, которые могут работать с более сложными изображениями.

Недавно предложена автоматизированная система диагностики медицинских изображений с использованием глубокой CNN (патент США 9589374 В1 03.07.2017). Это изобретение позволяет применять CNN к анализу медицинских изображений для диагностики патологий в реальном времени. Данная система использует анализ изображений цифровой маммографии, которые обрабатываются с использованием двух CNN и программных модулей, чтобы получить вероятности обнаружения областей интереса на изображениях, которые в дальнейшем изучаются лечащим врачом.

Автоматический анализ изображений цифровой маммографии рассматривается в работе [27] для задачи обнаружения патологий печени с использованием CNN со специальной архитектурой U-NET.

Классификаторы часто применяют предварительную обработку изображений с использованием метода нормализации яркости изображения N4ITK [28], который статистически значительно улучшает качество последующей сегментации. После этого изображение преобразуется так, чтобы математическое ожидание и отклонение яркости равнялись 0 и 1 соответственно.

Переход от последовательности двумерных изображений к трехмерным позволяет получить больше информации об исследуемом объекте. Показана эффективность трехмерных CNN для сегментации областей интересов [29]. Структура используемой трехмерной CNN отличается использованием двухканальной сети, то есть, сначала сеть обучается обнаруживать области интереса, а затем определяется внешний вид её структуры. Основным недостатком такого решения является выбор параметров CNN и их настройка. Настройка не разделяет ответы по весовым коэффициентам с последующим их повторным взвешиванием в слоях каждой CNN, а также не рассматривает обучающую выборку по типу патологии во время обучения, что приводит к большим ошибкам при распознавании структурных изменений на рентгеновских снимках. Таким образом, такое решение не может быть использовано для анализа рентгеновских изображений.

Хотя глубокое обучение продемонстрировало преимущество перед традиционными методами, оно остается трудно реализуемым на практике при значительных внутриклассовых различиях и межклассового сходства клинических патологий. Однако CNN широко используется для классификации маммографических изображений [30]. Существует решение задачи классификации рентгеновских изображений с помощью нескольких CNN с глубоким обучением (DCNN), одновременно позволяя им учиться друг у друга [31]. Каждая пара DCNN имеет полно-связанную структуру и предсказывает, принадлежит ли пара входных изображений к одному классу. Таким образом, если одна DCNN выполняет правильную классификацию, ошибка, сделанная другой DCNN, приводит к ошибке, которая позволяет дополнительно обновлять модель. Эта модель может проходить сквозное обучение под контролем ошибок классификации из DCNN и ошибок из каждой пары DCNN. Однако в настоящее время нет алгоритмов обучения с подкреплением для автоматического поиска архитектуры DCNN, параллельных вычислений модели и оптимизации структуры для масштабирования модели [31].

2.1. Предварительная обработка изображений

Мы использовали следующие методы для предварительной обработки исходных рентгеновских изображений. Прежде всего, необходимо преобразовать необработанные файлы PGM (.pgm) в формат изображения .tif из базы данных MIAS [32]. После чего, необходимо нормализовать изображение до диапазона значений 256 уровней серого. Кроме того, для увеличения контрастности изображения важно выполнить выравнивание гистограммы, что позволит увеличить общий контраст изображения (см. Рис. 1). Также необходимо улучшить качество изображения с помощью алгоритма переключающийся билатеральной фильтрации [33, 34, 35], чтобы уменьшить шумы и заполнить небольшие дыры на изображении.

Поскольку области интереса на изображениях, предоставленные в базе данных MIAS, имеют разные размеры, необходимо применить масштабирование к изображениям с учетом соотношения сторон, определенного как $r = w/h$, где r — соотношение сторон, w и h — ширина и высота изображения, соответственно. Большинство предварительно обученных моделей сетей используют размер изображения 224×224 (ширина, высота). При дискретизации с шагом меньше единица использовалась кубическая интерполяция, тогда как при дискретизации с шагом

больше единица использовалась интерполяционная формула Гаусса. Кроме того, изображения с соотношением сторон ниже 0,5 и выше 1,5 из набора данных MIAS не использовались.

2.2. Трансферное обучение

Для правильного обучения CNN требуются большой объем данных [36]. В области медицины обычно сложно получить такие большие наборы данных, что связано не только с ограниченным количеством исследований, но и с объемом ручной работы, необходимой для аннотации образцов. В данной работе будет использован подход трансфертного обучения; то есть, используется CNN, которая ранее была обучена для другой задачи на большой базе данных, а для задачи классификации патологий молочной железы и выполняется ее дообучение.

При этом предварительно обученные сети использовались как средство извлечения признаков, то есть все слои замораживаются, и только последний полно-связанный слой исходного классификатора повторно обучается. После чего происходит тонкая настройка всей сети с малой скоростью обучения, чтобы надежно классифицировать доброкачественные и злокачественные образования по маммографическим изображениям.

Были выбраны следующие предобученные нейронные сети MobileNetV2, InceptionResNetV2, Xception и ResNetV2 для разработки нового алгоритма классификации патологий в цифровой маммографии.

3. КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

В этом разделе представлены результаты работы разработанного алгоритма классификации патологий молочной железы с использованием трансферного обучения и предобученных сетей MobileNetV2, InceptionResNetV2, Xception, ResNetV2.

Для оценки точности предложенного алгоритма классификации патологий использовалась открытая база данных MIAS. Эта база данных состоит из 330 изображений, которые разделены на 7 классов патологий. Только 118 изображений были дополнительно классифицированы по степени серьезности патологий. Эти изображения были распределены по классам следующим образом: 64 доброкачественные и 54 злокачественные опухоли.




Рис. 1. Примеры предварительно обработанных изображений из базы данных MIAS [32].

Таблица 1. Результаты точности классификации (%) предложенного алгоритма с использованием трансферного обучения и предобученных сетей: MobileNetV2, InceptionResNetV2, Xception и ResNetV2 с/без тонкой настройки (FT/WFT), с/без аугментации (DA/WDA).

Предобученные сети	WFT WDA	WFT DA	FT WDA	FT DA
MobileNetV2	75.3	91.7	94.6	95.8
InceptionResNetV2	71.4	89.4	88.8	91.3
Xception	70.7	74.5	82.4	87.6
ResNetV2	72.2	75.9	79.7	86.4

Мы использовали традиционные метрики для оценки эффективности, такие как точность (Ассигасу) классификации $Accuracy = \frac{TP+TN}{P+N}$, где P — это общее количество положительных или доброкачественных случаев, N — общее количество отрицательных или злокачественных случаев, TP — это количество истинно-положительных результатов классификации, то есть все доброкачественные случаи, которые классификатор правильно предсказывает как благоприятные, TN означает количество истинно-отрицательных результатов классификации.

В наших экспериментах обучение сети происходило в течение 10 эпох со скоростью обучения 0,001. Использовалось пакетное обучение с размером 32 изображения. Также использовался подход для аугментации данных с помощью геометрических преобразований: комбинаций зеркального отображения и поворотов на 90, 180 и 270 градусов, сдвига по высоте и ширине и случайного масштабирования. Исходный набор данных для обучения и тестирования состоял из 903 изображений доброкачественных опухолей и 772 изображений злокачественных опухолей. Набор для тестирования составляет 20%, а набор данных для обучения — 80%.

В Таблице 1 показаны результаты точности классификации предложенного алгоритма с использованием трансферного обучения и предобученных сетей: MobileNetV2, InceptionResNetV2, Xception и ResNetV2. Результаты показывают, что трансферное обучение для каждой из предобученных нейронных сетей проходит успешнее, если использовать аугментацию и точную настройку сети. В итоге была выбрана предобученная нейронная сеть MobileNetV2, которая показывает точность 95,8%, что превосходит точность 78,4% лучшего результата для сети Resnet50 в работе [19].

4. ЗАКЛЮЧЕНИЕ

В данной работе был предложен новый алгоритм классификации патологий молочной железы в цифровой маммографии с использованием сверточной нейронной сети и трансферного обучения. Были выбраны предобученные нейронные сети: MobileNetV2, InceptionResNetV2, Xception и ResNetV2. Все изображения предварительно обработаны для повышения надежности классификации. Результаты экспериментов показывают, что трансферное обучение в каждой из предобученной нейронной сети дает лучший результат, если использовать аугментацию и точную настройку сети. В итоге была выбрана предобученная нейронная сеть MobileNetV2, которая позволяет с точностью 95,8% классифицировать патологии молочной железы.

СПИСОК ЛИТЕРАТУРЫ

1. Bray F., Ferlay J., Soerjomataram I. et al. Global cancer statistics 2018: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries // CA: A Cancer Journal for Clinicians. 2018. Vol. 68, no. 6. P. 394–424.
2. Diaz-Escobar J., Kober V. Classification of breast abnormalities in digital mammography using phase-based features // Proc. SPIE. Vol. 11137. 2019. P. 1113724.
3. J. Diaz-Escobar V. Kober V. K. M. M. Recognition of breast abnormalities using phase features // Journal of Communications Technology and Electronics. 2020. Vol. 65, no. 12. P. 1476–1483.

4. Al-antari M. A., Al-masni M. A., Choi M.-T. et al. A fully integrated computer-aided diagnosis system for digital x-ray mammograms via deep learning detection, segmentation, and classification // *International Journal of Medical Informatics*. 2018. Vol. 117. P. 44–54.
5. Pedro R. W. D., Machado-Lima A., Nunes F. L. Is mass classification in mammograms a solved problem? - a critical review over the last 20 years // *Expert Systems with Applications*. 2019. Vol. 119. P. 90–103.
6. Trister A. D., Buist D. L. C. I. Will machine learning tip the balance in breast cancer screening? // *JAMA oncology*. 2017. Vol. 3. P. 1463–1464.
7. Mina L., Isa N. A. M. A review of computer-aided detection and diagnosis of breast cancer in digital mammography // *Journal of Medical Sciences*. 2015. Vol. 15. P. 110–121.
8. Bozek J., Mustra M., Delac K., Grgic M. A Survey of Image Processing Algorithms in Digital Mammography // *Recent Advances in Multimedia Signal Processing and Communications* / Ed. by Mislav Grgic, Kresimir Delac, Mohammed Ghanbari. Berlin, Heidelberg : Springer Berlin Heidelberg, 2009. P. 631–657.
9. Salama M., Eltrass A., Elkamchouchi H. An improved approach for computer-aided diagnosis of breast cancer in digital mammography // *2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*. 2018. 06. P. 1–5.
10. Doi K. Computer-aided diagnosis in medical imaging: Historical review, current status and future potential // *Computerized medical imaging and graphics : the official journal of the Computerized Medical Imaging Society*. 2007. 06. Vol. 31. P. 198–211.
11. Halalli B., Makandar A. Computer Aided Diagnosis - Medical Image Analysis Techniques // *Breast Imaging* / Ed. by Cherie M. Kuzmiak. Rijeka : IntechOpen, 2018.
12. Murakami R. Detection of breast cancer with a computer-aided detection applied to full-field digital mammography // *Journal of digital imaging*. 2013. Vol. 26. P. 768–773.
13. Boughorbel S., Al-Ali R., Elkum N. Model comparison for breast cancer prognosis based on clinical data // *PloS one*. 2016. Vol. 11. P. e0146413.
14. Shrivastava A., Chaudhary A., Kulshreshtha D. et al. Automated digital mammogram segmentation using dispersed region growing and sliding window algorithm // *2017 2nd International Conference on Image, Vision and Computing (ICIVC)*. 2017. P. 366–370.
15. Morra L. Breast cancer: Computer-aided detection with digital breast tomosynthesis // *Radiology*. 2015. Vol. 277. P. 56–63.
16. Leonov S., Vasilyev A., Makovetskii A., Kober V. Analysis of the convolutional neural network architectures in image classification problems // *Proc.SPIE*. Vol. 11137. 2019. P. 111372E.
17. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. MIT Press, 2016.
18. Abdelsamea M. M., Mohamed M. H., Bamatraf M. Automated classification of malignant and benign breast cancer lesions using neural networks on digitized mammograms // *Cancer Informatics*. 2019. Vol. 18. P. 1176935119857570.
19. Falconi L. G., Perez M., Aguilar W. G. Transfer learning in breast mammogram abnormalities classification with mobilenet and nasnet // *2019 International Conference on Systems, Signals and Image Processing (IWSSIP)*. 2019. P. 109–114.
20. Mohamed H., Mabrouk M. S., Sharawy A. Computer aided detection system for micro calcifications in digital mammograms // *Computer Methods and Programs in Biomedicine*. 2014. Vol. 116, no. 3. P. 226–235.
21. Charate A., Jamge S. The preprocessing methods of mammogram images for breast cancer detection // *International Journal on Recent and Innovation Trends in Computing and Communication*. 2017. Vol. 5. P. 261–264.
22. Eddaoudi F., Regragui F. Microcalcifications detection in mammographic images using texture coding // *Applied Mathematical Sciences*. 2011. 01. Vol. 5. P. 381–393.

23. Charan S., Khan M. J., Khurshid K. Breast cancer detection in mammograms using convolutional neural network // 2018 International Conference on Computing, Mathematics and Engineering Technologies (iCoMET). 2018. P. 1–5.
24. Kober V. Robust and efficient algorithm of image enhancement // IEEE Transactions on Consumer Electronics. 2006. Vol. 52. P. 655–659.
25. Kober V. Fast recursive computation of sliding dht with arbitrary step // Sensors. 2020. Vol. 20. P. 5556.
26. Singh V. K., Rashwan H. A., Romani S. et al. Breast tumor segmentation and shape classification in mammograms using generative adversarial and convolutional neural network // Expert Systems with Applications. 2020. Vol. 139. P. 112855.
27. Christ P., Ettlinger F., Grün F. et al. Automatic liver and tumor segmentation of ct and mri volumes using cascaded fully convolutional neural networks // Scientific Reports. 2018. Vol. 8. P. 15497.
28. Tustison N. J., Avants B. B., Cook P. A. et al. N4itk: Improved n3 bias correction // IEEE Transactions on Medical Imaging. 2010. Vol. 29, no. 6. P. 1310–1320.
29. Kamnitsas K., Ledig C., Newcombe V. F. et al. Efficient multi-scale 3d cnn with fully connected crf for accurate brain lesion segmentation // Medical Image Analysis. 2017. Vol. 36. P. 61–78.
30. Zhou Z., Shin J., Zhang L. et al. Fine-tuning convolutional neural networks for biomedical image analysis: Actively and incrementally // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017. P. 4761–4772.
31. Zhang J., Xie Y., Wu Q., Xia Y. Medical image classification using synergic deep learning // Medical Image Analysis. 2019. Vol. 54. P. 10–19.
32. <http://peipa.essex.ac.uk/info/mias.html>.
33. Ruchay A., Kober V. Impulsive noise removal from color images with morphological filtering // Analysis of Images, Social Networks and Texts. Cham : Springer International Publishing, 2018. P. 280–291.
34. Ruchay A., Kober A., Kolpakov V., Makovetskaya T. Removal of impulsive noise from color images with cascade switching algorithm // Proc.SPIE. Vol. 10752. 2018. P. 1075224–12.
35. Ruchay A., Dorofeev K., Kalschikov V. A novel switching bilateral filtering algorithm for depth map // Computer Optics. 2019. Vol. 43, no. 6. P. 1001–1007.
36. Perre A. C., Alexandre L. A., Freire L. C. Lesion classification in mammograms using convolutional neural networks and transfer learning // Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization. 2019. Vol. 7, no. 5-6. P. 550–556.

Classification of breast abnormalities using deep convolutional neural network and transfer learning

Ruchay A.N., Kober V.I., Dorofeev K.A., Karnaukhov V.N., Mozerov M.G.

A new algorithm for classification of breast pathologies in digital mammography using a convolutional neural network and transfer learning is proposed. The following pretrained neural networks were chosen: MobileNetV2, InceptionResNetV2, Xception and ResNetV2. All mammographic images were pre-processed to improve classification reliability. Transfer training was carried out using additional data augmentation and fine-tuning. The performance of the proposed algorithm for classification of breast pathologies in terms of accuracy on real data is discussed and compared with that of the state-of-the-art algorithms on the available MIAS database.

KEYWORDS: classification abnormalities, digital mammography, deep convolutional neural network, transfer learning, data augmentation, fine-tuning.