ТЕОРИЯ И МЕТОДЫ ОБРАБОТКИ ИНФОРМАЦИИ

Сегментация образований груди в цифровой маммографии на основе глубокой сверточной нейронной сети U-net¹

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 30.05.2022

Аннотация—Предложен новый алгоритм сегментации образований груди в цифровой маммографии на основе глубоких сверточных нейронных сетей U-net. Все исходные изображения маммограмм предварительно обработаны для повышения надежности сегментации. Было проведено глубокое обучение с использованием дополнительных методов аугментации данных и тонкой настройки нейронной сети. Обсуждается эффективность предложенного алгоритма сегментации образований молочной железы на известной базе данных CBIS-DDSM.

КЛЮЧЕВЫЕ СЛОВА: сегментация, цифровая маммография, глубокая сверточная нейронная сеть U-net, аугментация данных

DOI: 10.53921/18195822 2022 22 2 63

1. ВВЕДЕНИЕ

Рак молочной железы является глобальной проблемой в области здравоохранения среди женщин во всем мире [1–4]. Только раннее его выявление может снизить уровень смертности и увеличить выздоровление. Таким образом, раннее выявление имеет решающее значение для улучшения прогноза рака молочной железы. Существует множество инструментов и стратегий контроля для визуализации и анализа рака молочной железы, такие как рентген, термография, эхография, МРТ и УЗИ. Тем не менее, маммография в настоящее время является наиболее эффективным методом раннего выявления рака молочной железы. Маммограмма — это изображение молочной железы, при котором используется рентгеновское излучение в малых дозах для визуализации и выявления рака. Однако анализ образований при маммографии остается сложной задачей из-за низкой контрастности изображений и плотности ткани молочной железы. Поэтому радиологи могут иногда пропустить обнаружение аномалий, если они ставят диагноз только на основании опыта. Поэтому в последнее десятилетие активно разрабатываются системы автоматизированной компьютерной диагностики.

Сегментация интересующих объектов на изображении — одна из основных проблем в анализе цифровых изображений [5–7]. Точная сегментация увеличивает эффективность последующих алгоритмов классификации, а также позволяет уменьшить время вычислений. Равита и др. [8] предложили модель глубокой контролируемой (deep supervised) U-Net в сочетании с плотными условными случайными полями (dense conditional random fields, CRFs) для сегментации образований молочной железы на маммограммах, что позволяет эффективно устранить некоторые ложные срабатывания. Сан и др. [9] предложили сеть с высокой плотностью дискретизации и управляемым вниманием (Attention guided dense-Upsampling Networks, AUNet)

¹ Исследование поддержано грантом Российского научного фонда (проект № 22-19-20071).

для сегментации образований молочной железы на маммограммах. AUNet обращает внимание на богатые информацией каналы, встраивая механизм внимания к каналу в блок повышающей дискретизации (upsampling block), направленный на извлечение полезной информации из высоко- и низкоуровневых характеристик. Это позволяет улучшить производительность сети, однако AUNet улавливает контекст только в канальном измерении, игнорируя контекст в пространственном измерении, что является недостаточным. Чен и др. [10] предложили многомасштабную состязательную сеть (multiscale adversarial network), которая использует мультисостязательное обучение для извлечения многомасштабной информации. Получилось улучшить U-Net сеть, добавив сеть дискриминации, которая использует три сверточные критические сети (convolutional critic networks) для разных масштабов, чтобы различать входные маски. В данной статье представлен разработанный новый метод сегментации образований молочной железы с использованием глубоких сверточных нейронных сетей U-net.

Работа организована следующим образом. В разделе 2 обсуждаются похожие работы. В разделе 3 представлены предлагаемые методы предобработки изображений маммограмм и подходы к сегментации аномалий груди в цифровой маммографии на основе глубоких сверточных нейронных сетей U-net. В разделе 4 описаны результаты компьютерного моделирования по сегментации образований груди с точки зрения точности. Наконец, в разделе 5 представлены наши выводы.

2. ОБЗОР АЛГОРИТМОВ СЕГМЕНТАЦИИ ОБРАЗОВАНИЙ ГРУДИ В ЦИФРОВОЙ МАММОГРАФИИ

В статье [11] был 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 [11], подтверждает идею о том, что использование CNN может надежно распознавать форму опухоли только на основе морфологической информации. Автоматический анализ изображений цифровой маммографии рассматривается в работе [12] для задачи обнаружения патологий печени и используется CNN со специальной архитектурой U-Net.

Хай и др. [13] предложили сеть DenseNet на основе U-Net сети, которая размещает модуль ASPP в самом глубоком пропускном соединении для сегментации образований молочной железы на маммограммах. Ли и др. [14] разработали DenseNet сеть на основе U-Net с методом переключение внимания (attention gate method) для сегментации образований молочной железы на маммограммах. Метод переключения внимания помогают выделять области интереса и подавлять остальные области. В работе [15] был предложен модуль адаптивного канала и многомасштабного пространственного контекста, который обладает более гибкими и эффективными возможностями обнаружения контекстной информации, и который встроен в ResNet на основе U-Net многоуровневым образом.

В статье [16] представлен гибридный подход к сегментации медицинских изображений с использованием интуиционистского нечеткого множества и нечеткого мягкого множества в области многогранных грубых множеств (intuitionistic fuzzy set and fuzzy soft set in the field of multigranulation rough set domain, IFSRCM) для маммограмм. Предложенный метод IFS-RCM позволяет более точно разделить аномальные ткани, такие как поражения, уплотнения и узлы молочной железы, что помогает в раннем выявлении рака молочной железы. Преимуществом предложенной модели сегментации является то, что она может работать с неопределенными и шумными изображениями маммограмм, используя нижнее и верхнее приближение

с помощью инструмента параметризации и сокращение признаков с помощью грубых мягких множеств. Она также поддерживает систематическую кластеризацию с инициализации центроидов кластеров гистограммными методами. Коэффициент сходства с использованием мягкого множества приводит к быстрой сходимости, что в свою очередь снижает временную сложность сегментации.

Сегментация образований на маммограммах в основном страдает от проблем, связанных с двумя аспектами: образование молочной железы может быть различных форм и размеров, а также перекрытие образования нормальной областью. В последнее время было опубликовано несколько работ для решения вышеупомянутых двух проблем. В работе Sun et al. [9] авторы разработали сеть плотной выборки на основе внимания (attention-guided dense-upsampling network), для прямой сегментации образования на маммограммах, где для уточнения характеристик использовался подход с привлечением каналов. Однако в их работе метод внимания (channel- attention) использовал только одномасштабный признак, а именно глобальное усредненное содержание признаков. Равита и др. [8] разработали U-сеть с глубоким контролем (DS-UNet), где использовали адаптивное выравнивание гистограмм с ограничением контраста для предварительной обработки исходных маммограмм. Затем обработанные изображения были поданы в DS-UNet. Наконец, выходная карта сегментации была уточнена с помощью плотных условных случайных полей (dense conditional random fields). В работе Чена и др. [10] была предложена многомасштабная состязательная сеть, включающую сеть сегментации в виде улучшенной U-сети для создания маски подозрительных областей и сеть дискриминации для различения входных масок, чтобы сегментировать массу молочной железы на всех маммограммах. Совмещение расстояния Earth-Mover и взвешенных потерь кросс-энтропии было использовано в качестве функции потерь во время обучения для получения лучших результатов сегментации и облегчения проблемы несбалансированных классов. В работе Ванга и других [17] был разработан эффективный метод внимания для U-Net сети в качестве генератора сети. CNN с модулем многомасштабного объединения была использована в качестве сети дискриминатора для обучения признаков у образований молочной железы различных размеров и форм. Тем не менее, последние два метода имеют недостаток, связанный с трудностью обучения. Например, в работе Chen et al. [10] для стабилизации процесса обучения их модели использовалась спектральная нормализация. В работе [18] была предложена адаптивная сеть рецептивного поля (ARF-Net) для точной сегментации образований молочной железы на маммографических и ультразвуковых изображениях. ARF-Net состоит из модуля селективного рецептивного поля (SRFM), включающий модуль множественного рецептивного поля (MRFM) и эффективный модуль многомасштабного выбора (MSSM). Модуль селективного рецептивного поля (SRFM) в ARF-Net используется для выбора приблизительного размера рецептивного поля для образований молочной железы различных размеров. MRFM предназначен для получения пространственной информации различных размеров. Эффективный MSSM предназначен для выбора подходящего размера рецептивного поля для молочных желез разного размера.

В исследовании [19] представлен новый метод многокритериальной оптимизации для сегментации образований молочной железы на маммограммах. Предложенная модель включает три этапа, такие как сбор изображений, шумоподавление и сегментация. Используются методы нормализации изображения и адаптивного выравнивания гистограммы с ограничением контраста (CLAHE) для улучшения визуальных возможностей и контрастности маммографических изображений. Затем используется метод оптимизации (EML) для сегментации нераковых и раковых частей маммограммы. Предлагаемый метод EML включает в себя такие преимущества, как повышенная надежность для анализа деталей изображения и адаптивность к локальному контексту.

РУЧАЙ, КОБЕР, ДОРОФЕЕВ, КАРНАУХОВ, МОЗЕРОВ

3. АЛГОРИТМ СЕГМЕНТАЦИИ ОБРАЗОВАНИЙ ГРУДИ В ЦИФРОВОЙ МАММОГРАФИИ НА ОСНОВЕ U-NET

3.1. База данных CBIS-DDSM

База данных CBIS-DDSM (Curated Breast Imaging Subset of DDSM) представляет собой обновленную и стандартизированную версию цифровой базы данных скрининговой маммографии (Digital Database for Screening Mammography, DDSM). DDSM — это база данных 2 620 отсканированных пленочных маммографических исследований. Она содержит нормальные, доброкачественные и злокачественные случаи с проверенной информацией о патологии. База данных CBIS-DDSM включает подмножество данных DDSM, отобранных и верифицированных рентгенологом. Изображения были декомпрессированы и преобразованы в формат DICOM. Также в базу включены улучшенные маски областей интереса (region of interest, ROI), рамки областей и диагноз о патологии [1].

Набор данных CBIS-DDSM содержит 1028 случая кальцификации и 1592 случая образования. Каждое изображение маммограммы состоит из четырех изображений, два для левой груди и два для правой. Съемка каждой груди производится в кранио-каудальном (CC) и медио-латеральном-обликовом (MLO). Вид MLO на маммограмме позволяет увидеть всю молочную железу целиком включая ткани молочной железы, сосок, лимфатическиеП узлы и грудную мышцу, расположенные либо в верхнем левом, либо в верхнем правом углу изображения [3].

Для одной и той же груди пациентки могут быть сделаны две маммограммы, каждая с разным видом MLO и CC. Каждая из этих маммограмм содержит 3 вида изображений: полное сканирование маммограммы (фактическая маммограмма); обрезанное изображение (увеличенное изображение образования); маска области интереса (двоичная маска, которая определяет местоположение образования). Из 1592 случая образования 71 случая содержит более одного образования, поэтому 71 маммограмма будут иметь более одно бинарной маски (по одной на каждую аномалию). На Рис. 1 представлены изображения для одного случая из базы данных CBIS-DDSM.



Рис.1. Примеры изображений из базы данных CBIS- DDSM [1]: маммограмма, маска образования и обрезанное, увеличенное образование (слева направо).

СЕГМЕНТАЦИЯ АНОМАЛИЙ ГРУДИ В ЦИФРОВОЙ МАММОГРАФИИ

3.2. Предварительная обработка изображений

Предварительная обработка изображений является необходимой подготовкой данных для обучения и использования в модели с целью стандартизации входа в нейронную сеть, улучшения качества изображений, улучшение извлечения особенностей и закономерностей на изображениях. Этапы предварительной обработки бинарных масок области интереса соответствует этапам обработки изображений для полных сканов маммограммы в части изменения размеров и отображения изображения (Шаг 1, Шаг 4, Шаг 6, Шаг 9). Мы использовали следующие методы для предварительной обработки исходных рентгеновских изображений маммограмм из базы данных CBIS-DDSM.

Шаг 1. Обрезка краев. Некоторые изображения имеют белую рамку на некоторых или всех сторонах кадра. Убирая небольшой процент изображения со всех сторон, можно удалить эту границу, не удаляя при этом слишком большую часть изображения, чтобы не потерять ценную информацию. Алгоритм обрезает 1% с левой и правой стороны изображения, и 4% сверху и снизу изображения. На разных изображениях маммограмм границы имеют разную толщину. В ходе ряда экспериментов было обнаружено, что этот алгоритм обрезки изображения хорошо подходят для удаления большинства границ. Результаты обрезки маммограммы для базы данных CBIS-DDSM приведены на Рис. 2.



Рис. 2. Пример результата обрезки маммограммы из базы данных CBIS-DDSM [1]: оригинальное изображение, обрезанное изображение (слева на право).

Шаг 2. Удаления шума на изображениях маммограмм. Необходимо улучшить качество изображения с помощью алгоритма переключающейся билатеральной фильтрации [20], что позволит уменьшить шумы и заполнить небольшие дыры на изображении.

Шаг 3. Выделение области груди и последующего удаления артефактов. На маммограммах могу присутствовать различные артефакты, плавающие на заднем плане. Артефакты могут быть разного размера и интенсивности, которые могут располагаться практически в любой части изображения, в зависимости от направления, в котором находится грудь. Поэтому важным этапом предобработки маммограмм является удаление артефактов. В результате остается только область груди на маммограмме, а все остальное становится черным фоном. Алгоритм состоит из следующих шагов: 1) бинаризация маммограммы с помощью пороговой обработки для создания бинарной маски, где 0 означает фоновый пиксель, а 1 — пиксель, принадлежащий области молочной железы, артефакту или шуму; 2) расширение границы белых контуров в маске с помощью морфологической операции открытия, что гарантирует захват всей об-

ласти любых артефактов, включая ее границы; 3) определение области груди на бинарной маске. Определяем все белые контуры в маске, вычисляем площади для каждого контура и сортируем контуры по площади. Можно определить контур груди как контур с наибольшей площадью. Результаты алгоритма выделения области и последующего удаления артефактов приведены на Рис. 3.



Рис. 3. Пример результата алгоритма выделения области и последующего удаления артефактов маммограммы из базы данных CBIS-DDSM [1]: оригинальное изображение, бинарная маска маммограммы, бинарная маска с расширением границ белых контуров, бинарная маска с выделенной областью груди, изображение после применения бинарной маски (слева направо).

Шаг 4. Стандартизация направления груди. В наборе данных CBIS-DDSM [1] большинство участков молочной железы находятся слева от маммограммы и обращены вправо. Этот шаг стандартизирует направление, в котором обращена грудь на всех маммограммах, что упрощает на шаге 6 процесс нормализации размера маммограммы. Поскольку вся область груди расположена слева, то для расширения размера изображения необходимо заполнить только правый край маммограммы. Алгоритм сначала проверяет, нужно ли перевернуть маммограммы. Для этого она сравнивает сумму значений пикселей в левой и правой половине маммограммы. Если второе значение больше первого, то это означает, что область груди находится справа, и ее нужно симметрично отобразить. Результаты алгоритма стандартизации направления груди приведены на Рис. 4.

Шаг 5. Повышение контрастности тканей молочной железы. Для повышения контрастности полутоновых изображений маммограмм был использовал алгоритм контрастно-ограниченного адаптивного выравнивания гистограммн (CLAHE), что помогает визуально выявлять мелкие детали, текстуры и особенности маммограммы и улучшает обучения модели. Результаты алгоритма повышения контрастности тканей молочной железы с помощью алгоритма CLAHE приведены на Рис. 5.

Шаг 6. Нормализация размера изображения маммограммы. Так как модели принимают на вход квадратные изображения, то необходимо добавить некоторое количество столбцов черных пикселей к правому краю изображений. Поскольку после выполнения шага 3 фон остается полностью черным, добавление черных пикселей не приведет к появлению произвольного края в конечном квадратном изображении. Результаты алгоритма нормализации размера изображения маммограммы приведены на Рис. 6.

Шаг 7. Удаление изображения грудной мышцы. Грудная мышца обычно используется для сравнения симметрии правой и левой груди, что может быть ранним признаком рака молочной железы. Фактически, грудная мышца выглядит более ярко на маммографических изображениях. Она имеет сходную интенсивность с аномалиями, поэтому важно исключить эту область



Рис. 4. Пример результата алгоритма стандартизации направления груди маммограммы из базы данных CBIS-DDSM [1]: оригинальное изображение, симметрично отображение изображение (слева направо).



Рис. 5. Пример результата алгоритма повышения контрастности тканей молочной железы с помощью алгоритма CLAHE на маммограмме из базы данных CBIS-DDSM [1]: оригинальное изображение, изображение с повышенной контрастностью тканей молочной железы (слева направо).

из рассмотрения, поскольку ее наличие может привести к обнаружению ложноположительных результатов. Мы использовали алгоритм, удаляющий изображения грудной мышцы на цифровых маммограммах с помощью преобразования Хафа [21]. Результаты алгоритма удаления изображения грудной мышцы на маммограмме приведены на Рис. 7.

Шаг 8. Нормализация. Маммограммы сохраняются в виде 16-битных массивов в файлах формата ".dcm", где значения пикселей находятся в диапазоне от 0 до 65535. Такие большие целые значения могут потенциально замедлить процесс обучения нейронной сети, поэтому хорошей практикой является нормализация значений в диапазоне [0,1].

Шаг 9. Поскольку области интереса на изображениях, предоставленные в базе данных CBIS-DDSM [1], имеют разные размеры, то мы изменили размер изображения с учетом соотношения сторон, определенного как r = w/h, где r — это соотношение сторон, w и h — ширина и высота изображения соответственно. Соотношение сторон было рассмотрено для изменения размера изображения как параметр, который помогает сохранить наилучшее качество исходного изображения, как при повышении, так и при понижении дискретизации. Большин-



Рис. 6. Пример результата алгоритма нормализации размера изображения маммограммы из базы данных CBIS-DDSM [1]: оригинальное изображение, итоговое нормализированное изображение маммограммы (слева направо).



Рис. 7. Пример результата алгоритма удаления изображения грудной мышцы на маммограмме из базы данных CBIS-DDSM [1]: оригинальное изображение, итоговое изображение маммограммы (слева на право).

ство предварительно обученных моделей используют размер изображения 224x224 (ширина, высота). Для повышающей дискретизации использовалась кубическая интерполяция, а для понижающей дискретизации интерполяционная формула Гаусса дает лучшие результаты.

3.3. Дополнение изображений

При ограниченном количестве изображений мы имеем небольшую вариативность данных, что может привести к чрезмерному переобучению модели. Чтобы решить эту проблему, мы дополнили наши обучающие данные синтезированными изображениями. Увеличение количества изображений может быть использовано для искусственного создания новых обучающих данных из существующих, а также для внесения изменчивости в набор данных.

Существует множество вариантов модификации изображений, но только подходящие модификации могут улучшить модель. При выборе подходящих модификаций одним из наиболее важных факторов является то, что модификации должны действительно создавать реали-

стичные изображения, которые имеют значение для задачи сегментации. Были выбраны следующие модификации изображений: случайное горизонтальное отображение изображения с вероятностью 50%; случайное вертикальное отображение изображения (с вероятностью 50%); случайное изменение яркости. На Рис. 8 представлена примеры модификации изображений для дополнения изображений маммограмм из базы данных CBIS-DDSM [1].



Рис. 8. Примеры дополнения изображений маммограмм из базы данных CBIS-DDSM [1].

3.4. Модель сегментации на основе U-Net архитектуры

Роннебергер и др. разработали архитектуру U-Net и опубликовали в своей статье [22] в 2015 году. U-Net стала распространенной архитектурой, используемой для задач сегментации. На Рис. 9 представлена архитектура U-Net, которая состоит из двух основных частей: блока кодера (верхняя половина диаграммы) и блока декодера (нижняя половина диаграммы), два блока вместе образуют U- образную форму.



Рис. 9. Архитектура модели VGG U-Net с входом маммограммы и маски.

РУЧАЙ, КОБЕР, ДОРОФЕЕВ, КАРНАУХОВ, МОЗЕРОВ

Блок кодера изучает особенности и выделяет признаки на изображении, после блок декодера семантически проецирует эти признаки низкого разрешения обратно в пространство пикселей полного разрешения исходного входного изображения, давая нам карту сегментации полного разрешения. Блок кодера — это традиционная последовательность сверточных слоев и слоев max-pooling, которая представляет собой типичную архитектуру сверточной нейронной сети (CNN), используемую для задач классификации, но без полносвязных выходных слоев (FCN). В качестве FCN чаще всего берут предобученную нейронную сеть CNN, например, AlexNet, VGG-16 или ResNet. Для сегментации была выбрана VGG-16 нейронная для блока кодера без FCN. Блок декодера — это нейронная сеть из свертки с повышающей выборкой и слоев конкатенации, симметричная блоку кодера. Как видно из Рис. 9, выбранные карты признаков из блока кодера объединяются в соответствующие слои блока декодера. Ранние слои CNN обычно изучают низкоуровневые признаки, в то время как более поздние слои изучают более высокоуровневые признаки, что позволяет U-сети объединить признаки, изученные на всех уровнях, для создания окончательной карты сегментации с полным разрешением и прогнозом.

4. КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

В этом разделе представлены результаты разработанного алгоритма сегментации образований груди в цифровой маммографии на основе глубокой сверточной нейронной сети U-Net.

Мы оценили эффективность предложенного алгоритма сегментации образований груди на основе U-Net на базе данных CBIS-DDSM [1], которая состоит из 1592 случая образования. В наших экспериментах обучение сети происходило в течение 43 эпох со скоростью обучения 0,00001. Использовалось пакетное обучение с размером 16 изображений. Также использовался подход для дополнения данных с помощью комбинации случайного горизонтального отображения с вероятностью 50%, случайного вертикального отображения изображения изображения с вероятностью 50%, случайного вертикального отображения изображения с вероятностью 50%, случайного вертикального отображения изображения с а набор для тестирования составляет 20%, а набор данных для обучения — 80%.

В качестве функции потерь L для обучения модели была использована объединенная функция потерь Дайс (Dice) и функция бинарной перекрестной энтропии (BCE — Binary Cross Entropy), которая определяется как:

$$L = L_{Dice} + \alpha L_{BCE},$$

где α — весовая константа, которая используется для настройки компромисса между Dice и BCE. Значение α выбрано равным 0,8.

Мы использовали традиционные метрики для оценки эффективности, такие как точность сегментации *Accuracy*, показатель того, как часто алгоритм делает правильное сегментирование. Эта метрика определяется как:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN},$$

где TP — число истинно-положительных результатов, когда экземпляр положительного класса корректно предсказывается моделью, как принадлежащий к положительному классу; TN число истинно-отрицательных результатов, когда экземпляр отрицательного класса корректно предсказывается моделью, как принадлежащий к отрицательному классу; FP — число ложноположительных результатов, когда экземпляр отрицательного класса неверно предсказан моделью, как принадлежащий к положительному классу; FN — число ложно-отрицательных результатов, когда экземпляр положительного класса неверно предсказан моделью, как принадлежащий к отрицательному классу.

Для вычисления коэффициента успешного обнаружения образования измеряется степень перекрытия *IoU* между областью нахождения образования, полученной с помощью алгоритма, и заранее точно известной областью нахождения образования. Степень перекрытия определяется как

$$IoU = \frac{\|r_t \cap r_0\|}{\|r_t \cup r_0\|},$$

где r_t — область образования, найденная с помощью алгоритма, r_0 — точно известная область образования, \cap и \cup — операции пересечения и объединения, соответственно, $\|\cdot\|$ — количество пикселей в области.

В результате экспериментов на базе данных CBIS-DDSM [1] средняя точность сегментации Accuracy равнялась 81,31 % со среднеквадратичным отклонением 0,78 % и средняя степень перекрытия IoU была 65,24 % со среднеквадратичным отклонением 21,96 % для предложенного алгоритма сегментации образований груди в цифровой маммографии на основе глубокой сверточной нейронной сети U-Net. Также важно посмотреть на предсказанные маски с наименьшим IoU. На Рис. 10 показано, что модель плохо справляется с сегментацией массовых аномалий, когда аномалии очень малы, или когда в области груди есть паутина плотных тканей молочной железы, или то и другое. Средняя степень перекрытия IoU около 65 % с отклонением 22 %



Рис. 10. Результаты визуализации предложенного алгоритма сегментации образований груди в цифровой маммографии на основе глубокой сверточной нейронной сети U-Net на базе данных CBIS-DDSM с плохой сегментацией массовых аномалий: исходная маммограмма, маска образования и предсказанная маска образования (слева на право).

на самом деле довольно хороша для задачи сегментации, и возможным объяснением такого низкого *IoU* может быть форма маски, которую выдает модель. В будущем возможна работа с формой маски. Также возможным объяснением может быть то, что модель плохо справляется

с сегментацией массовых образований, когда в области груди есть паутина плотных тканей молочной железы или образования достаточно малы. На Рис. 11 представлены результаты визуализации алгоритма сегментации образований груди в цифровой маммографии на основе глубокой сверточной нейронной сети U-Net. Предложенная модель сегментации с точностью



Рис. 11. Результаты визуализации предложенного алгоритма сегментации образований груди в цифровой маммографии на основе глубокой сверточной нейронной сети U-Net на базе данных CBIS-DDSM [1]: исходная маммограмма, маска образования и предсказанная маска образования (слева направо).

сегментации 81,31 %, что может быть успешно использовано врачами в ранней диагностике и лечении рака молочной железы.

5. ЗАКЛЮЧЕНИЕ

В данной работе был предложен алгоритм сегментации образований груди в цифровой маммографии на основе глубокой сверточной нейронной сети U-net. Все изображения предварительно обработаны для повышения точности сегментации. В ходе экспериментов была получена оценка эффективности предложенной модели на основе точности сегментации *Accuracy* и степени перекрытия *IoU*, где предложенная модель в среднем достигла 81,31% точности сегментации и 65,24% степени перекрытия на базе данных CBIS-DDSM [1]. Предложенная модель сегментации эффективно выделяет образования молочной железы, что может быть успешно использовано врачами в ранней диагностике и лечении рака молочной железы.

СПИСОК ЛИТЕРАТУРЫ

 Lee R., Gimenez F., Hoogi A. et al. A curated mammography data set for use in computer-aided detection and diagnosis research // Scientific Data. 2017. Vol. 4. P. 170177.

- Diaz J., Kober V., Karnaukhov V., Mozerov M. Recognition of breast abnormalities using phase features // Journal of Communications Technology and Electronics. 2020. 12. Vol. 65. P. 1476–1483.
- Lbachir I., Daoudi I., Tallal S. Automatic computer-aided diagnosis system for mass detection and classification in mammography // Multimed Tools Appl. 2021. Vol. 80. P. 9493–9525.
- Ruchai A., Kober V., Dorofeev K. et al. Classification of breast abnormalities using a deep convolutional neural network and transfer learning // Journal of Communications Technology and Electronics. 2021. Vol. 66. P. 778–783.
- Ahmed L., Iqbal M., Aldabbas H., Saeed S. Images data practices for semantic segmentation of breast cancer using deep neural network // Journal of Ambient Intelligence and Humanized Computing. 2020. 01.
- Siddique N., Paheding S., Elkin C. P., Devabhaktuni V. U-net and its variants for medical image segmentation: A review of theory and applications // IEEE Access. 2021. Vol. 9. P. 82031–82057.
- Punn N., Agarwal S. Modality specific u-net variants for biomedical image segmentation: a survey // Artificial Intelligence Review. 2022. Vol. 55.
- N R. R., Ranganathan V., N E., Ramesh N. Deeply supervised u-net for mass segmentation in digital mammograms // International Journal of Imaging Systems and Technology. 2021. Vol. 31, no. 1. P. 59–71.
- Sun H., Li C., Liu B. et al. Aunet: Attention-guided dense-upsampling networks for breast mass segmentation in whole mammograms // Physics in Medicine & Biology. 2019. Vol. 65.
- Chen J., Chen L., Wang S., Chen P. A novel multi-scale adversarial networks for precise segmentation of x-ray breast mass // IEEE Access. 2020. Vol. 8. P. 103772–103781.
- 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.
- Christ P., Ettlinger F., Grun 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.
- Hai J., Qiao K., Chen J. et al. Fully convolutional densenet with multiscale context for automated breast tumor segmentation // Journal of Healthcare Engineering. 2019. Vol. 2019.
- Li S., Dong M., Du G., Mu X. Attention dense-u-net for automatic breast mass segmentation in digital mammogram // IEEE Access. 2019. Vol. 7. P. 59037–59047.
- Zhao W., Lou M., Qi Y. et al. Adaptive channel and multiscale spatial context network for breast mass segmentation in full-field mammograms // Applied Intelligence. 2021. Vol. 51, no. 12. P. 8810–8827.
- Ghosh S. K., Mitra A., Ghosh A. A novel intuitionistic fuzzy soft set entrenched mammogram segmentation under multigranulation approximation for breast cancer detection in early stages // Expert Systems with Applications. 2021. Vol. 169. P. 114329.
- 17. Wang Y., Wang S., Chen J., Wu C. Whole mammographic mass segmentation using attention mechanism and multiscale pooling adversarial network // Journal of Medical Imaging. 2020. Vol. 7. P. 054503.
- Xu C., Qi Y., Wang Y. et al. Arf-net: An adaptive receptive field network for breast mass segmentation in whole mammograms and ultrasound images // Biomedical Signal Processing and Control. 2022. Vol. 71. P. 103178.
- SS I., RH H. Segmentation of breast masses in mammogram image using multilevel multiobjective electromagnetism-like optimization algorithm // BioMed Research International. 2022. Vol. 2022. P. 8576768.
- 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.

- Vagssa P., Doudou N. M., Jolivo T. et al. Pectoral muscle deletion on a mammogram to aid in the early diagnosis of breast cancer // International Journal of Engineering, Science and Technology. 2020. Vol. 12, no. 3. P. 57–65.
- Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Cham : Springer International Publishing, 2015. P. 234–241.

Segmentation of breast masses in digital mammography based on a deep convolutional neural network U-net

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

A new algorithm for segmentation of breast masses in digital mammography based on a convolutional neural network U-net is proposed. All images are preprocessed to improve segmentation reliability. Deep learning with data augmentation techniques and neural network fine-tuning is performed. The performance of the proposed algorithm for segmentation of breast masses on the known CBIS-DDSM database is presented and discussed.

KEYWORDS: segmentation, digital mammography, deep convolutional neural network U-net, data augmentation.