

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ АНАЛИЗЕ DICOM-ИЗОБРАЖЕНИЙ ПАТОЛОГИЙ ВНУТРЕННИХ ОРГАНОВ, ПОЛУЧЕННЫХ С ПОМОЩЬЮ УЗ-АППАРАТА

¹Тихоненко И. В., ²Мещеряков Ю. В., ³Стефанин А. Л.

¹*Институт повышения квалификации и переподготовки кадров здравоохранения УО «Белорусский государственный медицинский университет»,
Минск, Беларусь, direktorrima@tut.by,*

²*Институт повышения квалификации и переподготовки кадров здравоохранения УО «Белорусский государственный медицинский университет»,
Минск, Беларусь, direktorrima@tut.by,*

³*Институт повышения квалификации и переподготовки кадров здравоохранения УО «Белорусский государственный медицинский университет»,
Минск, Беларусь, direktorrima@tut.by*

Аннотация. Анализ медицинских изображений используется как основной метод диагностики многих заболеваний. В таком случае от ранней диагностики зависит как быстро человек получит необходимое лечение и насколько длительный курс реабилитации будет необходимо пройти. Использование технологий искусственного интеллекта и компьютерного зрения позволит увеличить долю выявления дородовых патологий внутренних органов и рака молочной железы на ранних стадиях, а также снизить риск врачебной ошибки при постановке диагноза.

Ключевые слова: AI, DICOM, TPS, OpenCV, Pandas, NumPy, Keras, DICE, TensorFlow.U-Net, ResUnet, ResUnet++, UNet++.

Abstract Medical imaging analysis is used as the primary method for diagnosing many diseases. In this case, how quickly a person will receive the necessary treatment and how long a rehabilitation course will need to be completed depends on early diagnosis. The use of artificial intelligence and computer vision technologies will increase the proportion of detection of antenatal pathologies of internal organs and breast cancer in the early stages, as well as reduce the risk of medical error during diagnosis.

Keywords: AI, DICOM, TPS, OpenCV, Pandas, NumPy, Keras, DICE, TensorFlow.U-Net, ResUnet, ResUnet++, UNet++.

Введение.

Использование технологий искусственного интеллекта и компьютерного зрения позволит увеличить долю выявления у женщин рака молочной железы на ранних стадиях на 10 %, сократить количество ненужных и травмирующих биопсий доброкачественной ткани 20 %, а также снизить риск врачебной ошибки при

постановке диагноза. Диагностическая ценность маммографии в возрастной категории моложе 50 лет заметно снижается с учетом рентгеновской плотности тканей МЖ у женщин репродуктивного возраста. Снижение экономической целесообразности маммографического скрининга в возрасте старше 70 лет обусловлено торпидностью течения заболевания и невысокой ожидаемой продолжительностью жизни. Важным методом диагностики в выявлении РМЖ на ранней стадии является ультразвуковое исследование, при котором определяется неоднородность внутренней структуры, наличие синдрома внутреннего эха и акустическое затенение позади образования. Зачастую УЗИ молочных желез дополняется эластографией, что повышает информативность метода и помогает доктору в выборе дальнейшей тактики ведения пациента [1–4].

Современное развитие технологии компьютерного зрения с использованием глубоких сверточных сетей для сегментации медицинских изображений в последнее время сделало большой вклад в процесс оказания медицинской помощи. Сегментация изображения – это процесс разделения входного изображения на несколько наборов пикселей одинаковой природы для выделения целевой области, которая интересует исследователей, превращая медицинское изображение в значимый объект для диагностических процессов. Мы выбрали U-Net в качестве основы сетевой архитектуры. Она имеет структуру сверточной сети, которая хорошо себя зарекомендовала в задачах сегментации медицинских изображений. Это сквозная, полностью сверточная сеть от пикселя к пикселю, обеспечивающая эффективное обучение по всему изображению за раз и плотное прогнозирование для семантической сегментации по пикселям. На рис. 1 показана его структура кодер-декодер с серией пропущенных соединений. Кодировщик сокращает выборки и постепенно уменьшает пространственное измерение за счет объединения слоев для извлечения объектов, а декодер восстанавливает детали изображения и пространственные размеры за счет увеличения дискретизации, что дает U-Net возможность плавно сегментировать изображения произвольного размера с помощью стратегии перекрытия.




Рисунок 1 – Оригинальная структура U-Net для сегментации биомедицинских изображений

Трансфертное обучение (ТО) – еще один заслуживающий внимания метод, реализованный в этом исследовании. Он основан на применении ранее получен-

ных знаний для решения новых аналогичных проблем более эффективным и действенным образом. ТО позволяет обучать модель на меньшем объеме данных, что делает ее особенно полезной при сегментации медицинских изображений. Одним из распространенных применений ТО в задачах классификации и сегментации является использование моделей CNN, предварительно обученных в ImageNet, таких как VGGNet, ResNet, AlexNet и Inception и т. д. Мы взяли эту идею и реализовали ее на U-Net. Недавние исследования предложили идею предварительной подготовки U-Net с помощью набора данных в оттенках серого, который более специфичен для сегментации в целом. Мы объединили идею ТО в U-Net с двумя подходами, упомянутыми выше в нашей сегментации и оценили их эффективность.

Before and after using AI




Рисунок 2 – Патология молочной железы

В настоящее время архитектура U-Net широко используется в сегментации медицинских изображений, которая была впервые разработана в 2015 году для сегментации изображений клеток под микроскопом с целью быстрой и точной сегментации с использованием ограниченного количества обучающих изображений. В 2020 году статьи, связанные с U-Net, охватывали различные методы получения медицинских изображений, а мозг и патология были наиболее распространенными областями применения. Было проведено несколько исследований в которых применялась базовая U-Net, в частности, по сегментации ультразвуковых исследований (УЗИ), например, для сегментации легких и сердца плода и ультразвуковая сегментация нервов на Kaggle Challenge в 2016 году.

В качестве оценочного показателя был выбран коэффициент Dice. Это индекс пространственного перекрытия в диапазоне от 0 до 1, указывающий на отсутствие пространственного перекрытия до полного перекрытия между двоичной предсказанной маской и разметкой врача. Это статистический инструмент, который может четко представлять сходство между двумя наборами данных. Уравнение выглядит следующим образом:

$$DICE(f, x, y) = \frac{2 \times \sum_{ij} f(x)_{ij} \times y_{ij} + \epsilon}{\sum_{ij} f(x)_{ij} + y_{ij} + \epsilon}$$

В котором x – входное изображение;
 y – фактическая истинность;
 $f(x)$ – результат прогнозирования модели. ε это небольшое число, добавляемое, чтобы избежать деления на ноль [5].

Модель была обучена с использованием графических процессоров NVIDIA GeForce RTX 2060 Super. Модель была реализована с помощью PyTorch с использованием библиотеки MONAI.

Наибольший коэффициент Дайса был получен для УЗИ изображений молочной железы – $9,3 \pm 3,1$ %

Полученные результаты обученной системы искусственного интеллекта при определении патологий молочной железы: accuracy = 91,29 %, PPV = 56,4, NPV = 86,1, Se = 95,1 %, Sp = 96,2 %.

Для обучения AI необходимо приведение к одному формату и размеру; затемнение областей, коррекция контрастности. Для повышения точности сегментации были предложены несколько методов дополнительной предварительной обработки изображений. Реализовано несколько моделей сверхточных нейронных сетей: U-Net, ResUnet, ResUnet++, UNet++, а также проведено сравнение точности сегментации для различных архитектур и методов предварительной обработки.

Заключение.

Обученные нейронные сети позволяют достигнуть точности ранней диагностики дородовой патологии и патологии молочной железы 91,29 %, что при использовании методики цифрового архивирования изображений в практике работы врачей ультразвуковой диагностики позволит повысить качество диагностики и обеспечить раннее выявление патологии.

Необходимо проведение дальнейших исследований со стандартизацией методики обучения нейронных сетей и использованием тестового набора данных.

Список использованных источников:

1. Чуканов, А. Н. Пути оптимизации методики пренатального ультразвукового скрининга врожденных пороков сердца / А. Н. Чуканов // Мед. панорама. – 2010. – № 6. – С. 24–30.
2. Чуканов, А. Н. Пренатальная диагностика врожденных пороков сердца на этапе ультразвукового скрининга беременных: значение, методика, перспективы / А. Н. Чуканов // Мед. панорама. – 2010. – № 2. – С. 75–79.
3. Чуканов, А. Н. Возможности сонографии в пренатальной диагностике врожденных пороков сердца / А. Н. Чуканов // Мед. панорама. – 2010. – № 3. – С. 51–55.
4. Сопич, И. В. Ранняя диагностика в маммологии / И. В. Сопич, И. В. Тихоненко // Лучевая визуализация заболеваний скелета и внутренних органов: сб. науч. работ, посвященный Дню рентгенолога (8 ноября); под ред. А. Н. Михайлова. – Минск : БелМАПО, 2022. – С. 119–123.
5. Lessmann N., B. van Ginneken, P. A. de Jong, and I. Išgum Iterative Fully Convolutional Neural Networks for Automatic Vertebra Segmentation and Identification // Medical Image Analysis, 53. – 2019. – P. 142–155.