

ОБЗОР МЕТОДОВ СЕГМЕНТАЦИИ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ

Смольская Т.С., Друз Э.В.

*Белорусский государственный университет информатики и радиоэлектроники,
г. Минск, Республика Беларусь*

Научный руководитель: Камлач П.В. – к.т.н., доцент, доцент кафедры ЭТТ

Аннотация. В статье представлен обзор современных методов сегментации медицинских изображений, применяемых при обработке данных компьютерной томографии. Рассмотрены классические алгоритмы сегментации, методы машинного обучения, а также современные нейросетевые архитектуры, используемые для выделения анатомических структур на медицинских изображениях. Проведен анализ преимуществ и ограничений различных подходов, а также рассмотрены перспективные направления применения методов глубокого обучения для автоматизации процесса сегментации и повышения точности построения трёхмерных моделей анатомических структур.

Ключевые слова: медицинские изображения, сегментация изображений, компьютерная томография, височная кость, среднее ухо, нейронные сети, глубокое обучение.

Введение. Современные методы медицинской визуализации играют ключевую роль в диагностике и лечении различных заболеваний. Одним из наиболее распространённых методов исследования костных структур является компьютерная томография (КТ).

Одной из важных задач обработки медицинских изображений является сегментация – процесс выделения отдельных анатомических структур на изображении [1]. Традиционно для решения задачи сегментации применялись классические методы обработки изображений, однако в последние годы значительное развитие получили методы машинного обучения и глубокого обучения, основанные на применении нейронных сетей. Особенно широкое распространение в медицинской визуализации получили сверточные нейронные сети (Convolutional Neural Networks, CNN), позволяющие автоматически извлекать признаки изображений и выполнять сегментацию с высокой точностью. Архитектуры семейства U-Net и их модификации стали стандартом в задачах сегментации медицинских изображений. Также активно развиваются трехмерные модели и гибридные архитектуры, сочетающие сверточные сети и механизмы внимания.

Несмотря на значительные успехи в данной области, задача сегментации медицинских изображений, особенно содержащих мелкие анатомические структуры, остаётся актуальной и требует дальнейших исследований [2].

Целью данной работы является обзор современных методов сегментации медицинских изображений и анализ их применимости для обработки данных компьютерной томографии.

Основная часть. Медицинские изображения обладают рядом особенностей, которые существенно усложняют задачу их автоматической обработки. К таким особенностям относятся наличие шумов, низкий контраст между различными типами тканей, а также высокая вариабельность анатомических структур у разных пациентов. Кроме того, медицинские изображения часто содержат артефакты, возникающие в процессе сканирования.

Компьютерная томография широко применяется для исследования костных структур, включая височную кость и анатомические структуры среднего и внутреннего уха. КТ позволяет получать высокодетализированные послойные изображения, однако даже при высоком разрешении выделение мелких анатомических объектов может представлять значительные трудности.

Сегментация медицинских изображений представляет собой процесс разделения изображения на области, соответствующие различным анатомическим структурам. Результаты сегментации используются при построении трёхмерных моделей органов, планировании хирургических вмешательств, разработке медицинских имплантов и проведении количественного анализа анатомических структур.

Особую сложность представляет сегментация малых анатомических объектов, характерных для области среднего и внутреннего уха. Такие структуры имеют небольшие размеры, сложную форму и часто располагаются в непосредственной близости друг от друга, что требует применения высокоточных методов обработки изображений.

До широкого распространения методов машинного обучения сегментация медицинских изображений осуществлялась с использованием классических алгоритмов обработки изображений [3].

Одним из наиболее простых подходов является пороговая сегментация, при которой выделение объектов производится на основе значения интенсивности пикселей. Данный метод отличается простотой реализации, однако его применение ограничено в случаях, когда различные ткани имеют схожие значения интенсивности [4].

К другой группе методов относятся алгоритмы, основанные на выделении границ объектов. Эти методы используют различные операторы обнаружения границ, позволяющие определить контуры анатомических структур. Однако они чувствительны к шумам и не всегда обеспечивают точное выделение сложных форм.

Также применяются методы кластеризации, например алгоритм k-means, который позволяет группировать пиксели изображения по сходству их характеристик. Подобные методы могут использоваться для предварительного разделения изображения на области, однако требуют дополнительной обработки для получения точных границ структур.

Для сегментации медицинских изображений также используются методы активных контуров и уровневых множеств. Эти методы позволяют более точно учитывать форму объектов, однако их применение часто требует значительных вычислительных ресурсов и настройки параметров.

Несмотря на широкое распространение классических методов, их эффективность при обработке сложных медицинских изображений ограничена, что привело к активному развитию методов машинного обучения.

В последние годы для сегментации медицинских изображений активно применяются методы глубокого обучения. Наибольшее распространение получили сверточные нейронные сети, которые позволяют автоматически извлекать информативные признаки из изображений.

Одной из наиболее известных архитектур является U-Net, предложенная для задач биомедицинской сегментации [5]. Данная архитектура имеет симметричную структуру типа «кодировщик-декодировщик». Кодировщик выполняет извлечение признаков изображения, постепенно уменьшая его пространственное разрешение, а декодировщик восстанавливает изображение, формируя карту сегментации.

Важной особенностью архитектуры U-Net является использование так называемых skip-соединений, которые позволяют передавать информацию между соответствующими уровнями кодировщика и декодировщика. Это позволяет сохранять пространственные детали изображения и повышает точность сегментации.

С момента появления U-Net было предложено большое количество её модификаций, направленных на повышение точности сегментации и улучшение обработки сложных медицинских изображений [6].

Медицинские томографические данные, получаемые с помощью компьютерной томографии и магнитно-резонансной томографии, представляют собой трёхмерные объёмные изображения. В связи с этим всё большее распространение получают методы трёхмерной сегментации.

Одним из наиболее известных подходов является архитектура 3D U-Net, которая представляет собой расширение классической U-Net для работы с трёхмерными данными. В данной архитектуре используются трёхмерные свёртки, позволяющие учитывать пространственные связи между соседними срезами томографического изображения [7].

Использование трёхмерных моделей позволяет более точно учитывать форму анатомических структур и их пространственное расположение. Однако такие модели требуют значительно больших вычислительных ресурсов и объёмов обучающих данных.

В последние годы активно развиваются гибридные модели, объединяющие преимущества сверточных нейронных сетей и механизмов внимания. Одним из таких

направлений является использование трансформеров в задачах сегментации медицинских изображений.

Архитектуры на основе трансформеров позволяют более эффективно учитывать глобальные зависимости между различными областями изображения. Примером таких моделей являются UNETR и Swin-UNet, которые демонстрируют высокие результаты при сегментации сложных медицинских изображений.

Использование механизмов внимания позволяет модели автоматически определять наиболее важные области изображения и концентрировать на них вычислительные ресурсы, что повышает точность сегментации.

Анализ существующих методов сегментации показывает, что классические алгоритмы обработки изображений обладают рядом ограничений и часто не обеспечивают необходимой точности при обработке сложных медицинских данных.

Методы глубокого обучения, основанные на сверточных нейронных сетях, демонстрируют значительно более высокие результаты. Архитектуры семейства U-Net стали одним из наиболее распространённых инструментов сегментации медицинских изображений благодаря их эффективности и относительной простоте реализации.

Современные трёхмерные и гибридные модели позволяют учитывать пространственную структуру данных и обеспечивают более точное выделение анатомических объектов. В то же время такие модели требуют значительных вычислительных ресурсов и большого объёма обучающих данных.

В связи с этим выбор архитектуры нейронной сети для конкретной задачи сегментации должен учитывать особенности исходных данных, размеры анатомических структур и доступный объём обучающей выборки.

Итоговые результаты сравнительного анализа архитектур нейронных сетей для сегментации структур среднего и внутреннего уха по данным КТ представлены в таблице 1.

Таблица 1 – Сравнительный анализ архитектур нейронных сетей для сегментации структур среднего и внутреннего уха по данным КТ

Группы методов	Представители	Преимущества	Недостатки
Классические методы	– пороговые; – методы, основанные на выделении границ; – региональные методы; – кластеризационные методы; – графовые и вариационные методы	– простота реализации; – низкие вычислительные затраты; – интерпретируемость результатов	– чувствительность к шуму; – ручная настройка; – низкая устойчивость к вариативности анатомии; – сложность работы с 3D
Сверточные нейронные сети (CNN)	FCN	– автоматическое извлечение признаков; – высокая точность	– потеря мелких деталей при downsampling
Полносверточная нейронная сеть с модификацией	U-Net	– сохранение деталей (пропускные соединения); – хорошая работа при малых выборках данных; – простота реализации	– сегментация по отдельным срезам может приводить к разрывам структуры в 3D; – риск переобучения
Сверточные нейронные сети U-Net с модификациями	ResU-Net, Dense U-Net	– улучшенная передача градиента; – более глубокие модели; – устойчивость к переобучению	– повышенная сложность разработки

Продолжение таблицы 1

Группы методов	Представители	Преимущества	Недостатки
	Attention U-Net	– фокусировка на релевантных областях; – лучшее выделение малых структур	– требуются дополнительные параметры; – усложнение обучения
	3D U-Net	– учет пространственной структуры; – целостность анатомии	– высокие требования к оборудованию
Гибридные CNN-Transformer модели	TransUNet, UNet++	– учет глобального контекста и локальных признаков; – высокая точность	– сложность реализации; – необходимость больших данных

Заключение. В данной работе был проведён обзор современных методов сегментации медицинских изображений. Рассмотрены классические алгоритмы обработки изображений, а также современные подходы, основанные на применении методов машинного обучения и глубокого обучения.

Проведённый анализ показал, что традиционные методы сегментации обладают рядом ограничений и не всегда обеспечивают необходимую точность при обработке сложных медицинских данных. В последние годы наибольшую эффективность демонстрируют методы, основанные на использовании сверточных нейронных сетей, в частности архитектуры семейства U-Net и их модификации.

Результаты проведённого обзора могут быть использованы при выборе архитектуры нейронной сети для решения задачи сегментации структур среднего и внутреннего уха на данных компьютерной томографии, а также при разработке методов автоматизированного построения трёхмерных моделей анатомических объектов.

Список литературы

1. Litjens G., Kooi T., Bejnordi B. et al. A survey on deep learning in medical image analysis // *Medical Image Analysis*. – 2017. – Vol. 42. – P. 60–88.
2. Shen D., Wu G., Suk H. I. Deep learning in medical image analysis // *Annual Review of Biomedical Engineering*. – 2017. – Vol. 19. – P. 221–248.
3. Pham D. L., Xu C., Prince J. L. Current methods in medical image segmentation // *Annual Review of Biomedical Engineering*. – 2000. – Vol. 2. – P. 315–337.
4. Heimann T., Meinzer H. P. Statistical shape models for 3D medical image segmentation: a review // *Medical Image Analysis*. – 2009. – Vol. 13(4). – P. 543–563.
5. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. – 2015. – P. 234–241.
6. Zhou Z., Siddiquee M. M. R., Tajbakhsh N., Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation // *Deep Learning in Medical Image Analysis*. – 2018. – P. 3–11.
7. Çiçek Ö., Abdulkadir A., Lienkamp S. S., Brox T., Ronneberger O. 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation // *MICCAI*. – 2016. – P. 424–432.

UDC 611.91

A REVIEW OF MEDICAL IMAGE SEGMENTATION METHODS

Smolskaya T.S., Druts E.V.

Belarusian State University of Informatics and Radioelectronics, Minsk, Republic of Belarus

Kamlach P.V. – Cand. of Sci., associate professor, associate professor of the department of ETT

Annotation. This article presents an overview of modern medical image segmentation methods applied in the processing of computed tomography data. The paper examines classical segmentation algorithms, machine learning techniques, and modern neural network architectures used for delineating anatomical structures in medical images. An analysis of the advantages and limitations of various approaches is conducted, and promising directions for applying deep learning methods to automate the segmentation process and enhance the accuracy of constructing three-dimensional models of anatomical structures are discussed.

Keywords: medical images, image segmentation, computed tomography, temporal bone, middle ear, neural networks, deep learning.