

## СЕГМЕНТАЦИЯ ОПУХОЛИ ГОЛОВНОГО МОЗГА НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ МУЛЬТИМОДАЛЬНЫХ ИЗОБРАЖЕНИЙ МОЗГА МРТ

*Джанибеков Х.Ш.*

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

*Научный руководитель: Чураков А.В. – к.м.н., доцент, доцент кафедры ЭТТ*

**Аннотация.** Экспериментально исследована новая архитектура сегментации опухолей головного мозга, которая извлекает выгоду из характеристики четырех методов МРТ. Установлено, что каждая модальность имеет уникальные характеристики, которые помогают сети эффективно различать классы. Продемонстрировано, что работа только с частью изображения мозга рядом с опухолевой тканью позволяет модели CNN (которая является самой популярной архитектурой глубокого обучения) достигать производительности, близкой к производительности человека-наблюдателя.

**Ключевые слова:** локализация и сегментация опухолей головного мозга, CNN, каскадная структура, модуль DWA

**Введение.** Локализация и сегментация опухолей головного мозга на основе данных магнитно-резонансной томографии (МРТ) представляют собой сложные и значимые задачи в области медицинского анализа. Каждый метод визуализации мозга обеспечивает уникальные и важные детали, касающиеся каждой части опухоли. В недавних исследованиях активно применялись четыре метода: T1, T1c, T2 и FLAIR. Хотя некоторые из этих методов показали многообещающие результаты сегментации на наборе данных BRATS 2018, они сталкиваются с сложной структурой, что требует длительного времени на обучение и тестирование.

В данной статье автором показано, что, устраняя около 80% несущественной информации каждого входного изображения, нет необходимости в сложной глубокой сети; выбирая примерно 20% всего изображения для каждой входной модальности и соответствующего нормализованного изображения по Z-оценке, остается меньше пикселей для исследования, что благоприятно влияет на обработку информации.

**Основная часть.** Локализация и сегментация опухолей головного мозга на основе данных магнитно-резонансной томографии (МРТ) представляют собой сложные и значимые задачи в области медицинского анализа. Каждый метод визуализации мозга обеспечивает уникальные и важные детали, касающиеся каждой части опухоли. В недавних исследованиях активно применялись четыре метода: T1, T1c, T2 и FLAIR. Хотя некоторые из этих методов показали многообещающие результаты сегментации на наборе данных BRATS 2018, они сталкиваются с сложной структурой, что требует длительного времени на обучение и тестирование [1].

Для создания гибкой и эффективной системы сегментации опухолей головного мозга решено использовать подход предварительной обработки, который позволяет работать лишь с небольшой частью изображения, а не со всем полностью. Этот метод значительно сокращает время вычислений и помогает избежать проблем переобучения в модели глубокого обучения.

Из-за небольшого размера опухолей по сравнению с остальным мозгом данные визуализации мозга несбалансированы. Из-за такой характеристики существующие сети оказываются смещенными в сторону одного класса, который перепредставлен, а обучение глубокой модели часто приводит к низким истинно положительным показателям. Кроме

того, существующие подходы глубокого обучения имеют сложную структуру, что делает их более трудоемкими.

В данном исследовании было замечено, что опухоль на каждом последующем срезе изображения либо растет, либо уменьшается (рисунок 1). Начиная с небольших размеров на первых срезах, опухоль может появиться в любой области изображения. Далее, на последующих срезах, видно, что опухоль остается на том же месте, но ее размер увеличивается. После достижения максимального размера опухоль начинает уменьшаться, пока полностью не исчезнет. Это основная идея моего метода предварительной обработки данных [2].

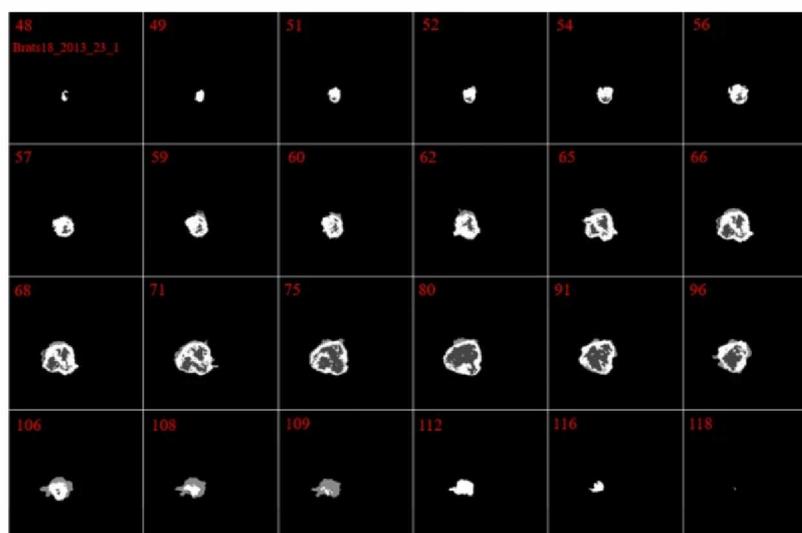


Рисунок 1 – Иллюстрация срезов новообразования

Поскольку модель CNN не сохраняет свои характеристики при вращении и изменении масштаба, сегментация объектов, подлежащих перемещению на изображении, становится сложной задачей. Одной из главных проблем, связанных с использованием модели CNN в области медицинской визуализации, является время вычислений, так как многие медицинские приложения требуют оперативной обработки данных, чтобы минимизировать необходимость дополнительного анализа и лечения. Эта проблема усугубляется, когда речь идет о многомерных медицинских изображениях. Следовательно, использование трехмерной модели CNN для обнаружения поражений с помощью стандартного метода скользящего окна становится неэффективным. Это особенно непрактично при работе с объемными изображениями высокого разрешения и необходимостью анализировать большие объемы трехмерных блоков. В случае всех объемных изображений головного мозга местоположение, размер, ориентация и форма опухоли различаются у разных пациентов, что приводит к затруднениям при обнаружении потенциальных опухолевых областей. Поэтому целесообразнее искать только небольшую часть изображения, а не выполнять анализ всего изображения [3].

Схема каскадного режима представлена на рисунке 2. Для того чтобы охватить максимальное количество характеристик опухоли, применяется четыре метода: инверсионное восстановление с ослаблением жидкости (Flair), контрастирование по T1 (T1C), взвешивание по T1 (T1), взвешивание по T2 (T2). Кроме того, добавляется четыре соответствующих нормализованных изображения Z-Score для каждой из четырех входных модальностей, чтобы улучшить оценку результатов сегментации, не увеличивая сложность данной структуры [3].

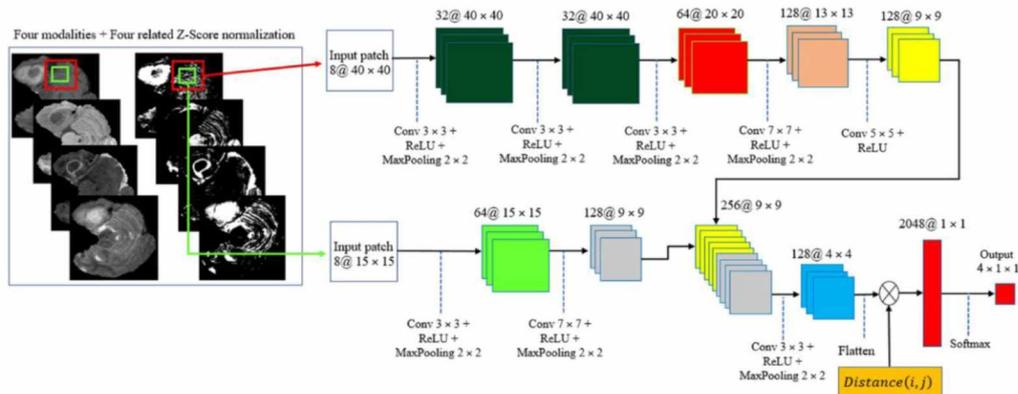


Рисунок 2 – Реализованная каскадная структура

Благодаря применению эффективного этапа предварительной обработки, который удаляет около 80% неинформативной информации из каждого входного изображения, нет необходимости в использовании сложной глубокой сети. Другими словами, отбирая примерно 20% всего изображения (этот процент является средним значением всех срезов пациента) для каждой входной модальности и соответствующего нормализованного изображения по Z-оценке, количество пикселей, требующих анализа, сокращается.

На рисунке 3 наглядно показаны хорошие результаты, достигнутые примененным методом на наборе данных. Как видно, все регионы имеют общую границу со всеми остальными регионами. Благодаря различиям между размером ядра опухоли и областями усиления внутри изображений T1C (третий столбец), границу между ними можно легко определить с высокой точностью без применения других методов. Однако это не так очевидно, когда речь идет о границе ядра опухоли, областях отека или усиленного отека. Благодаря указанным характеристикам каждой модальности становится понятно, что нет необходимости в использовании очень глубокой модели CNN, если ограничить область поиска [4].

Благодаря использованию модуля DWA используемая модель может получать более уникальную контекстную информацию из опухоли и мозга, что приводит к лучшему результату сегментации. На рисунке 4 показано улучшение сегментации в результате применения модуля DWA в предлагаемом методе, особенно на границе соприкасающихся областей опухоли [3].

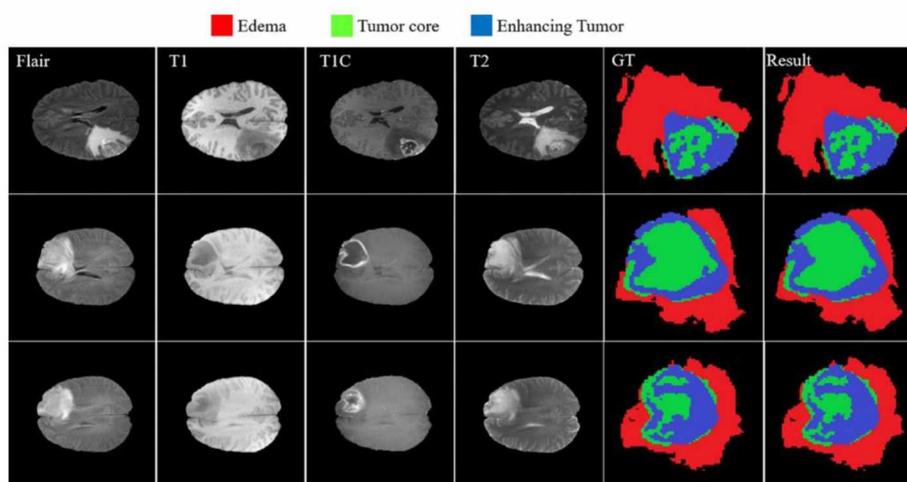


Рисунок 3 – Результаты сегментации новообразования

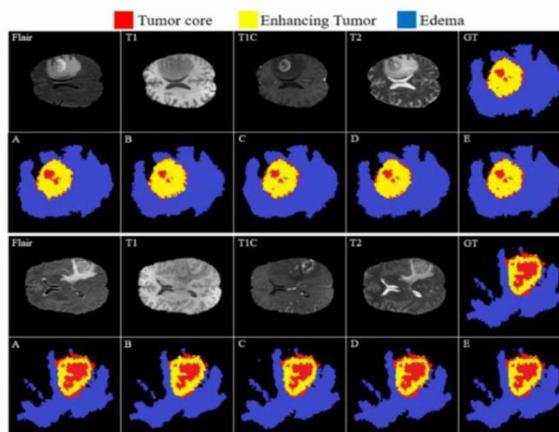


Рисунок 4 – Сравнение результатов сегментации опухоли головного мозга с использованием предложенной стратегии

**Заключение.** Выполнен анализ метода, в ходе которого после извлечения ожидаемой области опухоли с использованием мощного подхода предварительной обработки представленные участки выбираются для подачи в сеть информации о том, что их центр расположен внутри этой области. Доказано, что это приводит к сокращению времени вычислений и возможности быстрого прогнозирования классификации клинического изображения, поскольку на этапе предварительной обработки удаляется большое количество незначительных пикселей из изображения.

Несмотря на выдающиеся результаты предложенного подхода по сравнению с другими моделями, используемый алгоритм по-прежнему имеет ограничения при обнаружении опухоли объемом более одной трети всего мозга. Это связано с увеличением размера ожидаемой области опухоли, что приводит к снижению эффективности выделения признаков.

### Список литературы

1. Bakas, S. *Segmentation Labels and Radiomic Features for the Pre-operative Scans of the TCGA-GBM Collection*. *Cancer Imag.* (2017).
2. Menze, B. H. et al. *The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS)*. *IEEE Trans. Med. Imag.* 34(10), 1993–2024 (2015).
3. Zhang, D. et al. *Cross-Modality Deep Feature Learning for Brain Tumor Segmentation*. *Pattern Recognit.* (2020).
4. Chen, G., Li, Q., Shi, F., Rekik, I. & Pan, Z. *RFDCR: Automated Brain Lesion Segmentation Using Cascaded Random Forests with Dense Conditional Random Fields*. *Neuroimage* 211, 116620 (2020).

UDC 621.3.049.77–048.24:537.2

## BRAIN TUMOR SEGMENTATION BASED ON DEEP LEARNING USING MULTIMODAL MRI BRAIN IMAGES

*Djanibekov K.S.*

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

*Churakov A.V. – Cand. of Med. Sci., Associate Professor, Associate Professor of the Department of ETT*

**Annotation.** A new brain tumor segmentation architecture that benefits from the characterization of four MRI techniques is experimentally investigated. It is found that each modality has unique characteristics that help the network effectively distinguish between classes. It has been demonstrated that working with only the portion of the brain image near the tumor tissue allows the CNN model (which is the most popular deep learning architecture) to achieve performance close to that of a human observer.

**Keywords:** localization and segmentation of brain tumors, CNN, cascade structure, DWA module