

УДК 004.932.2

РАЗРАБОТКА ИИ-МОДЕЛИ СЕГМЕНТАЦИИ ТКАНЕЙ ГОЛОВНОГО МОЗГА

Бабич Н.С. (ИТМО), Белоусова К.М. (ИТМО), Аль-Хайдри В.А.А. (ИТМО)

Научный руководитель – кандидат технических наук, старший научный сотрудник
Бруй Е.А. (ИТМО)

Введение. Современная медицина требует повсеместной интеграции высоких технологий. С помощью магнитно-резонансной томографии возможно получать подробные изображения головного мозга с различными контрастами. Несмотря на это, задача анализа этих изображений всё еще занимает много времени и является трудоёмкой для специалистов. Автоматизированная сегментация позволяет повысить эффективность диагностики и анализа паталогических изменений головного мозга.

На сегодняшний день для решения задач сегментации применяются различные алгоритмы машинного обучения, в том числе классические методы, такие как кластеризация и пороговая бинаризация, а также нейросетевые модели – в основном на архитектуре свёрточных нейронных сетей. Для обучения нейросетевых моделей используют предварительно размеченные вручную данные. Разметка данных – трудоёмкая задача, требующая высокой квалификации специалиста-рентгенолога. Использование синтетических МР-изображений может позволить увеличить количество данных для обучения и повысить устойчивость обученных моделей к вариативности контрастов на изображениях.

Целью работы является повышение качества сегментации T1-взвешенных МР-изображений головного мозга за счет использования синтетических МР-изображений при обучении нейросетевой модели.

Основная часть. В качестве основной архитектуры свёрточной нейронной сети была выбрана U-Net [1]. Такая структура нейронной сети предлагает эффективное решение для задачи сегментации 2D медицинских изображений. Такая архитектура имеет ряд достоинств, среди которых высокая эффективность сегментации сложных анатомических структур, например, тканей лучезапястного сустава [2], универсальность при обработке различных данных, например, одинаково эффективно используются различные типы МР контрастов (T1, T2, FLAIR) для генерации масок одного и того же органа [3].

Для обучения был использован датасет, сгенерированный с помощью метода решения уравнений Блоха в численном виде в программном пакете KomaMRI [4]. Данный программный пакет позволяет симулировать МР-изображения для цифровых фантомов для заданных методов получения изображений (импульсных последовательностей). Было создано 1046 изображений головного мозга с T1-контрастом. В качестве основы для генерации цифровых фантомов был использован набор данных BrainWeb. [5]

Сеть была дообучена на данных датасета MR Brain Segmentation Challenge 2018, содержащих МР-изображения трех различных контрастов (T1, T1-IR, T2-FLAIR), сегментированные вручную экспертами [6]. В качестве масок было выделено 8 тканей головного мозга, включая серое и белое вещество, цереброспинальную жидкость, мозжечок и другие зоны.

Классическая архитектура нейронной сети (U-Net) была модифицирована с помощью механизмов батч-нормализации и слоёв исключения (dropout) для повышения устойчивости к переобучению и ускорения работы сети, в качестве функции потерь использована Dice Loss.

Весь функционал был реализован на языке Python с использованием библиотек Tensorflow, Keras.

Выводы. Разработана нейросетевая модель, которая показывает успешную возможность сегментации как реальных, так и синтетических МРТ изображений головного мозга на различные классы. Проверка работоспособности обученной нейронной сети осуществлялась вычислением коэффициента Соренса-Дайса (DSC) на тестовой выборке.

Список использованных источников:

1. Ronneberger, Olaf & Fischer, Philipp & Brox, Thomas. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. LNCS. 9351. 234-241. 10.1007/978-3-319-24574-4_28.
2. Бруй Е.А., Владимиров Н.А. Нейросетевые решения на основе архитектуры. U-Net для автоматической сегментации хрящевой ткани лучезапястного сустава на МР изображениях. Моделирование, оптимизация и информационные технологии. 2021;9(2). 10.26102/2310-6018/2021.33.2.012.
3. Sudre, C.H., Li, W., Vercauteren, T., Ourselin, S. and Jorge Cardoso, M. (2017) Generalised Dice Overlap as a Deep Learning Loss Function for Highly Unbalanced Segmentations. In: Cardoso, M., et al., Eds., Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. DLMIA ML-CDS 2017. Lecture Notes in Computer Science, Vol. 10553, Springer, Cham, 240-248, 10.1007/978-3-319-67558-9_28
4. Castillo-Passi, C, Coronado, R, Varela-Mattatall, G, Alberola-López, C, Botnar, R, Irarrazaval, P. KomaMRI.jl: An open-source framework for general MRI simulations with GPU acceleration. Magn Reson Med. 2023; 1- 14. doi: 10.1002/mrm.29635
5. C.A. Cocosco, V. Kollokian, R.K.-S. Kwan, A.C. Evans : "BrainWeb: Online Interface to a 3D MRI Simulated Brain Database" NeuroImage, vol.5, no.4, part 2/4, S425, 1997 -- Proceedings of 3-rd International Conference on Functional Mapping of the Human Brain, Copenhagen, May 1997.
6. Mendrik, Adriëne & Vincken, Koen & Kuijf, Hugo & Breeuwer, Marcel & Bouvy, Willem & de Bresser, Jeroen & Alansary, Amir & de Bruijne, Marleen & Carass, Aaron & El-Baz, Ayman & Jog, Amod & Katyal, Ranveer & Khan, Ali & Lijn, Fedde & Mahmood, Qaiser & Mukherjee, Ryan & Opbroek, Annegreet & Paneri, Sahil & Pereira, Sérgio & Viergever, Max. (2015). MRBrainS Challenge: Online Evaluation Framework for Brain Image Segmentation in 3T MRI Scans. Computational Intelligence and Neuroscience. 2015. 1-16. 10.1155/2015/813696.