

АЛГОРИТМ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ ОПУХОЛЕЙ ГОЛОВНОГО МОЗГА НА ОСНОВЕ U-СЕТИ С ОСТАТОЧНОЙ ПЛОТНОСТЬЮ МОДУЛЯ INCEPTION (IRDNU-NET)

Цяо Инъюань¹, Иванова Ю. А.²

¹ Томский политехнический университет, ИШИТР, магистрант гр. 8ВМ22, e-mail: insyuan1@tpu.ru

² Томский политехнический университет, ИШИТР, доцент, e-mail: jbolotova@tpu.ru

Введение

Сегментация опухолей мозга на магнитно-резонансной томографии (МРТ) остается активной темой исследований в области анализа медицинских изображений, однако сегментация опухолей мозга со сложной структурой требует более глубоких и широких моделей, что увеличивает вычислительную сложность и может привести к проблемам с исчезновением градиента [1]. С другой стороны, они неэффективны для выявления опухолей меньшего размера, а точная сегментация опухолей остается сложной задачей из-за неоднородного внешнего вида и множества типов опухолей мозга, а также высокой вариативности размеров, формы, расположения, интенсивности и контрастности опухолей мозга в различных модальностях визуализации. Чтобы решить эту проблему, мы предлагаем новую модель Inception Residual Dense Nested U-Net (IRDNU-Net) для алгоритма сегментации изображений опухолей мозга.

Основная часть

Эта алгоритмическая модель позволяет извлекать более представительные признаки из опухоли мозга, повышая тем самым точность сегментации. В этой модели вместо стандартных сверточных слоев U-Net используются сложные модули Residual и Inception для увеличения ширины модели без увеличения вычислительной сложности. Чтобы сделать структуру сети шире, стандартные сверточные слои, используемые в структуре U-Net, заменяются сложными модулями Residual Receiver кодера и декодера IRDNU-Net.

Используя наборы данных МРТ опухолей головного мозга BraTS 2019 и BraTS 2020. обучающий набор данных BraTS 2019 содержал 335 случаев, 259 случаев ГГМ и 76 случаев НГМ, а валидационный набор данных BraTS 2019 содержал 125 немаркированных случаев. Набор данных BraTS 2020, обучающий набор данных содержал 367 случаев, из них 293 случая из глиобластомы (GBM/HGG) и 76 случаев из глиомы низкого уровня (LGG).

Начальная остаточная плотная вложенная U-сеть (IRDNU-Net)

Предлагаемая модель IRDNU-Net для сегментации опухолей мозга опирается на ту же архитектуру кодера-декодера, что и модель U-Net. Как показано на рисунке 1, архитектура кодера-декодера углублена и расширена за счет объединения модуля Inception-Residual с переработанным путем пропуска, т.е. плотным соединением пропуска. Эта архитектура будет использоваться для сегментации опухоли мозга на основе четырех модальностей МРТ, т.е. FLAIR, T1, T2 и T1c. Архитектура U-Net - это архитектура кодера-декодера.

Кодер пытается постепенно уменьшить пространственную размерность карты признаков, захватывая при этом больше семантических признаков более высокого уровня. Тем временем декодер стремится восстановить особенности объекта и пространственную размерность. Поэтому важно захватить больше высокоуровневых признаков в кодере, а сохранение большего количества пространственной информации в декодере повышает эффективность сегментации [2]. На основе структуры кодера-декодера, модуля "начало-остаток" и плотной модели на рис. 1 показана предлагаемая структура, известная как IRDNU-сеть. Предлагаемая структура сети состоит из ветви кодера и ветви декодера. В каждом модуле кодера два сверточных слоя в оригинальной модели U-Net заменяются на предлагаемый модуль Inception-Residual, после чего выполняется операция 2×2 максимального множества для понижающей дискретизации. На каждом шаге понижающей дискретизации количество каналов признаков удваивается. Соответственно, в ветви декодирования выполняется такое же количество процессов апсемплинга для восстановления пространственного размера сегментированного выходного сигнала. Каждое повышение дискретизации достигается сверткой с транспонированием 2×2 , что вдвое уменьшает количество каналов признаков. В U-net сети карты признаков от кодера поступают непосредственно к декодеру; однако в предлагаемой модели, помимо блоков Inception-Residual, плотно вложенные пути соединяют кодер с декодером. Каждому блоку Inception-Residual назначается параметр P для управления

количеством фильтров сверточного слоя в этих блоках, чтобы обеспечить четкую взаимосвязь между количеством параметров в базовой модели U-Net и предлагаемой модели [3].

Комбинированная функция потерь

В системе глубокого обучения функция потерь имеет решающее значение, когда мы имеем дело с крайне несбалансированными данными. Правильный выбор функции потерь также может повысить точность модели. В данном исследовании мы используем комбинированную функцию потерь, определенную в уравнении (1), которая объединяет взвешенные потери кросс-энтропии (WCE), определенные в уравнении (2), и обобщенную функцию потерь Дайса (GDL), определенную в уравнении (3), для смягчения эффекта проблемы дисбаланса классов следующим образом:

$$CL = WCE + GDL \quad (1)$$

$$WCE = -\frac{1}{k} \sum_k \sum_i^L w_i g_{ik} \log(P_{ik}) \quad (2)$$

$$GDL = 1 - 2 \frac{\sum_i^L W_i \sum_k g_{ik} p_{ik}}{\sum_i^L W_i \sum_k (g_{ik} + p_{ik})} \quad (3)$$

Результаты

В данной работе мы оцениваем результаты сегментации с помощью метрики Дайса, чувствительности и специфичности. Метрика Дайса в первую очередь измеряет область перекрытия между размеченными данными и результатом сегментации, полученной на основе данных. Чувствительность часто называют истинно положительным показателем, в то время как специфичность используется для определения истинно отрицательного показателя и может быть рассчитана с помощью следующих уравнений соответственно.

$$DSC = \frac{2TP}{FP + FN + 2TP} \quad (4)$$

$$Sensitivity = \frac{TP}{FN + TP} \quad (5)$$

$$Specificity = \frac{FP}{FP + TP} \quad (6)$$

где TP, FN и FP обозначают истинно положительный, ложноотрицательный и ложноположительный результат соответственно.

Заключение

Начальная остаточная модель с вложенными плотными путями была разработана на основе U-Net для достижения высокой точности сегментации с меньшим количеством параметров. Согласно метрике Дайса, предложенный метод достигает уровня производительности, сравнимого с существующими методами сегментации опухолей мозга. Предложенная сеть достигла лучших результатов по сравнению с U-Net и другими методами. IRDNU-Net значительно превосходит U-Net и другие типичные методы сегментации опухолей мозга.

Список использованных источников

1. Дарган С., Кумар М., Айягари М.Р. Обзор глубокого обучения и его приложений Applications: Новая парадигма машинного обучения. – 2020. – Springer Netherlands. – Т.27(4). – С.1071–1092.
2. Szegedy C, Liu W, Jia Y. Going deeper with convolutions // Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition – 2015. – P. 1–9.
3. Drozdal M, Vorontsov E, Chartrand G. The importance of skip connections in biomedical image segmentation. In: Deep learning and data labeling for medical applications. – 2016. – Springer. – P. 179–187.