

Текере Ричард (Ботсвана)

Томский политехнический университет, г. Томск

*Научный руководитель: Спицын Владимир Григорьевич, доктор технических наук
профессор (ОИТ, ИШИТР)*

НЕЙРОСЕТЕВОЙ АНАЛИЗ МРТ-СНИМКОВ ДЛЯ ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ МОЗГА

Аннотация. В данном исследовании представлен подход на основе глубинного обучения для диагностики заболеваний головного мозга с использованием МРТ. Применяется архитектура TransUNet, интегрирующая сверточные нейронные сети (CNN), Vision Transformers и объяснимый искусственный интеллект (XAI). Предлагаемая система повышает точность сегментации и интерпретируемость, сокращая разрыв между исследованиями в области ИИ и их клиническим применением.

Ключевые слова: сегментация опухолей мозга, анализ МРТ, Vision Transformers, объяснимый ИИ.

Введение

Актуальность исследования обусловлена необходимостью точной диагностики заболеваний головного мозга с помощью МРТ. Современные нейросетевые методы, включая сверточные нейронные сети (CNN) и Vision Transformers (ViT), значительно повысили качество сегментации и анализа изображений. Архитектура TransUNet [1], объединяющая CNN и ViT, продемонстрировала высокую эффективность в задачах сегментации опухолей. Однако «черный ящик» глубинного обучения остается серьезным препятствием для внедрения в клиническую практику. Для решения этой проблемы были разработаны методы объяснимого ИИ (XAI), такие как Grad-CAM и SHAP, которые повышают прозрачность решений нейронных сетей [2].

В данном исследовании используется BraTS 2021 Task 1, эталонный набор данных для сегментации опухолей мозга, с целью оценки предложенной методологии. Система развернута в виде веб-приложения, позволяет радиологам загружать МРТ-сканы, автоматически сегментировать изображения, визуализировать объяснимость и экспортировать результаты. Цель исследования – создать клинически полезное веб-приложение, сочетающее высокую точность с интерпретируемостью, сокращая разрыв между исследованиями ИИ и медицинской практикой.

Обзор литературы и существующих решений

Развитие анализа медицинских изображений на основе МРТ связано с активным применением различных архитектур нейронных сетей. Классические 2D-CNN показали высокую эффективность в извлечении локальных признаков, однако ограничены в учёте объемной информации [3]. Модели 3D-CNN решают

эту проблему, но требуют значительных вычислительных ресурсов [6]. Для анализа временной динамики применяются гибридные модели CNN-RNN, эффективные при исследовании прогрессирующих заболеваний, таких как болезнь Альцгеймера [5].

Появление Vision Transformers (ViT) стало важным этапом в медицинской визуализации благодаря способности ViT улавливать глобальные зависимости и обрабатывать изображения как последовательность патчей [4]. Современные гибридные архитектуры, такие как TransUNet, объединяют CNN и ViT, что позволяет достигать высокой точности в задачах сегментации опухолей головного мозга, в том числе на эталонных наборах данных, таких как BraTS.

Проблема интерпретируемости решений остаётся критичной для внедрения ИИ в клинику. Для её решения применяются методы объяснимого ИИ – Grad-CAM и SHAP, позволяющие визуализировать вклад признаков в результат. Эти подходы создают основу для разработки точных и надёжных диагностических систем с высоким уровнем доверия со стороны специалистов.

Предлагаемая методология

Предлагаемая методология для сегментации опухолей мозга на основе TransUNet представлена на (Рис. 1). Она включает несколько этапов: предварительную обработку, извлечение признаков, сегментацию и объяснимость.




Рис. 1. Схематическое представление архитектуры Transnet для сегментации опухолей головного мозга на основе данных МРТ

Предварительная обработка

Входные МРТ-сканы проходят несколько этапов предварительной обработки:

1. Изменение размера – приведение всех изображений к фиксированному разрешению для соответствия требованиям модели.
2. Нормализация – масштабирование значений интенсивности пикселей в единообразный диапазон для улучшения работы модели.
3. Аугментация – применение преобразований, таких как поворот и изменение контраста, для повышения обобщающей способности модели.

Извлечение признаков (CNN-энкодер & Transformer-энкодер)

1. Процесс извлечения признаков начинается с CNN-энкодера, который выявляет локальные пространственные особенности. Преобразование на каждом слое определяется уравнением:

$$F_{l+1} = f(W_l \star F_l + b_l), \quad (1)$$

где F_l – входная карта признаков, W_l и b_l – обучаемые веса и смещения, f – функция активации, а $\star$ представляет собой операцию свертки, которая перемещает фильтр по входному изображению для извлечения пространственных шаблонов.

2. Трансформер-энкодер захватывает глобальные зависимости в изображении, обрабатывая признаки в виде вложенных последовательностей. Он вычисляет многоголовое само внимание (MSA) между фрагментами изображения:

$$MSA(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (2)$$

где Q, K, V – матрицы запроса, ключа и значения, а d_k – размерность ключевых векторов. Этот механизм позволяет модели фокусироваться на важных областях изображения, назначая более высокие веса внимания.

После применения многоголового самовнимания (MSA) согласно уравнению (2) трансформер-энкодер обрабатывает признаки с помощью многослойного персептрона (MLP), который состоит из двух полносвязных слоев с нелинейной функцией активации:

$$MLP(X) = \sigma(W_2(\text{ReLU}(W_1X + b_1)) + b_2) \quad (3)$$

где X – входное представление признаков, W_1, W_2 – весовые матрицы, b_1, b_2 – смещения, а σ – функция активации, такая как Softmax или ReLU. Каждый слой трансформера обновляет входные признаки в следующей последовательности:

$$z'_1 = MSA(LN(z_{1-1})) + z_{1-1}, \quad (4)$$

$$z_1 = MLP(LN(z'_1)) + z'_1, \quad (5)$$

где $LN(\cdot)$ представляет нормализацию слоя (Layer Normalization), $MSA(\cdot)$ применяет самовнимание по патчам изображения, а $MLP(\cdot)$ – это двухслойная полносвязная сеть, которая улучшает представления признаков. MSA-блок обучается выявлять контекстные взаимосвязи между различными регионами изобра-

жения, тогда как MLP-блок улучшает представления перед их передачей в следующий слой трансформера.

3. Объединение признаков (Feature Concatenation): извлеченные признаки CNN и Transformer объединяются перед передачей в декодер.

Сегментация (CNN-декодер и сегментационный слой)

1. CNN-декодер: реконструирует сегментационную маску путем постепенного увеличения разрешения признаков.
2. Сегментационный слой: заключительный слой использует 1×1 свертку для генерации пиксель-классификационной карты.

Модуль объяснимости (Grad-CAM & SHAP)

1. Grad-CAM (Gradient-weighted Class Activation Mapping): применяется к последнему слою CNN-энкодера для генерации тепловых карт, показывающих важные области сегментации. Grad-CAM генерирует тепловые карты, выделяя ключевые области изображения. Карта активации вычисляется следующим образом:

$$L_{Grad-CAM}^c = ReLU(\sum_k \alpha_k^c A^k), \quad (6)$$

где α_k^c – весовые коэффициенты значимости:

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y_c}{\partial A_{ij}^k}, \quad (7)$$

где A^k представляет карты признаков, а $\frac{\partial y_c}{\partial A_{ij}^k}$ обозначает градиент оценки класса относительно активаций признаков

2. Применяется к выходу трансформер-энкодера, выявляя, какие фрагменты изображения внесли наибольший вклад в решение о сегментации. Для интерпретации вклада трансформера в процесс сегментации используется SHAP (Shapley Additive Explanations), который позволяет количественно оценить важность признаков. Значение Шепли для каждого признака рассчитывается по формуле:

$$\phi_i = \sum_{S \subseteq F/\{i\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} [f(S \cup \{i\}) - f(S)], \quad (8)$$

где ϕ_i представляет вклад признака i в предсказание, а $f(S)$ – выход модели для данного подмножества признаков S . SHAP помогает определить наиболее значимые области изображения для сегментации.

Веб-ориентированный интерактивный инструмент

Django-ориентированное веб-приложение будет разработано для обеспечения

- 1) интерфейса загрузки МРТ – пользователи могут загружать сканы в формате DICOM/NIfTI.
- 2) автоматического анализа – загруженные изображения обрабатываются глубинной моделью.
- 3) модуля объяснимости – интерпретация результатов с помощью методов XAI.
- 4) визуализации для пользователя – наложение маркеров заболеваний и тепловых карт на МРТ.
- 5) функции экспорта – сохранение результатов в форматах PNG/PDF для дальнейшего анализа

Результаты

В рамках проекта была разработана и частично реализована веб-платформа под названием NeuroScore, предназначенная для сегментации опухолей головного мозга на основе МРТ-снимков. В системе используется модель глубокого обучения TransUNet в сочетании с инструментами объяснимого ИИ, такими как Grad-CAM и SHAP. Платформа разработана с использованием веб-фреймворка Django и предлагает интуитивно понятный и интерактивный интерфейс для врачей-радиологов. Ниже представлена главная страница приложения NeuroScore (рис. 2).

Модель находится в стадии разработки и нацелена на достижение коэффициента Dice (DSC) $> 0,85$. Для оценки качества сегментации используется открытый набор данных BraTS 2021 Task 1. Grad-CAM позволяет отображать ключевые зоны активации модели, а SHAP – количественно оценивать вклад отдельных признаков в итоговое решение. Применение этих подходов обеспечивает не только высокую точность, но и интерпретируемость модели, что упрощает её внедрение в клиническую практику.




Рис. 2. Главная страница приложения NeuroScore

Заключение

В данном исследовании предлагается система анализа МРТ на основе глубинного обучения, интегрирующая CNN, трансформеры и объяснимый ИИ для диагностики заболеваний головного мозга. Система предназначена для повышения точности и эффективности диагностики, обеспечивая интерпретируемость результатов благодаря использованию SHAP и Grad-CAM.

Кроме того, разработано веб-ориентированное интерактивное приложение, позволяющее радиологам автоматизировать процесс сегментации, анализировать объяснительные визуализации и экспортировать результаты для дальнейшей оценки. Планируется расширение набора данных, включающее более широкий спектр заболеваний головного мозга, что улучшит генерализацию модели.

Список литературы

1. Chen J., Lu Y., Yu Q., Luo X., Adeli E., Wang Y., Chang E.I.C., Xu Y. TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation. In: Medical Image Analysis. – 2021.
2. Selvaraju R. R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. Grad-CAM: Visual Explanations from Deep Networks. In: IEEE International Conference on Computer Vision. – 2017.
3. Bakas S., Reyes M., Jakab A., Bauer S., Rempfler M., Crimi A., Shinohara R. T., Berger C., Ha S. M., Rozycki M., Kirschke J. Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge. In: IEEE Transactions on Medical Imaging. – 2018.
4. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. In: arXiv preprint arXiv:2010.11929. – 2020.
5. Rafii M.S., Walsh S.J., Little B.C., Fogel A.L., Thompson P.M., Schwartz J.B. Artificial intelligence in brain MRI analysis of Alzheimer's disease over the past 12 years: A systematic review. Ageing Research Reviews. – 2022. DOI: 10.1016/j.arr.2022.101614.
6. Moradi E., Pepe A., Gaser C., Huttunen H., Tohka J. A parameter-efficient deep learning approach to predict conversion from mild cognitive impairment to Alzheimer's disease. NeuroImage. – 2019. DOI: 10.1016/j.neuroimage.2019.01.03