

УПРАВЛЕНИЕ АУГМЕНТАЦИЕЙ ДАННЫХ ДЛЯ РЕШЕНИЯ ЗАДАЧИ СЕГМЕНТАЦИИ СНИМКОВ УЗИ ЩИТОВИДНОЙ ЖЕЛЕЗЫ

Холод Д.В. (НИЯУ МИФИ), Боброва Е.В. (НИЯУ МИФИ)

Научный руководитель – доктор технических наук, профессор Зайцев К.С.
(НИЯУ МИФИ)

Введение. Ультразвуковая диагностика представляет собой один из базовых методов выявления узловых образований щитовидной железы, что обусловлено высокой доступностью метода и его неинвазивным характером. Вместе с тем интерпретация УЗИ-изображений во многом зависит от опыта врача и подвержена субъективным ошибкам, особенно при определении границ новообразований. В связи с этим актуальной научно-практической задачей является автоматическая сегментация узлов щитовидной железы с использованием методов глубокого обучения.

Современные модели сегментации изображений демонстрируют высокую эффективность [1], однако их обучение требует значительных объемов размеченных данных. В медицинской области получение таких данных затруднено из-за высокой стоимости и необходимости привлечения экспертов. Одним из распространённых способов компенсации ограниченного объема данных является аугментация — искусственное расширение обучающей выборки путём применения преобразований к исходным изображениям [2, 3]. При этом избыточная аугментация может приводить к ухудшению качества моделей, что делает актуальной задачу анализа и оптимизации её параметров.

Основная часть. В работе исследуется влияние доли аугментированных данных на качество сегментации узлов щитовидной железы на ультразвуковых изображениях. Вводится параметр R , определяемый как отношение числа аугментированных изображений к числу оригинальных. Рассматривается зависимость метрик качества сегментации от значения данного параметра.

Экспериментальные исследования проведены на датасете ультразвуковых изображений щитовидной железы DDTI с использованием различных архитектур энкодеров, включая ConvNeXt-Tiny, Swin Transformer-Tiny и Vision Transformer Base [4, 5, 6]. Качество сегментации оценивалось с использованием стандартных метрик, применяемых в задачах медицинской сегментации.

Результаты экспериментов показали, что зависимость качества сегментации от параметра R носит немонотонный характер. Для всех рассмотренных архитектур наблюдается наличие оптимального значения R_{\max} , при котором достигаются наилучшие показатели качества, а также области значений R_{\min} соответствующей деградации результатов. Установлено, что архитектуры ConvNeXt и Swin демонстрируют более высокую устойчивость к увеличению доли аугментированных данных, тогда как Vision Transformer характеризуется повышенной чувствительностью к избыточной аугментации.

Выводы. В работе проведён анализ влияния доли аугментированных данных на качество сегментации узлов щитовидной железы на УЗИ-изображениях. Показано, что аугментация данных требует аккуратного подбора параметров, поскольку её чрезмерное применение может приводить к ухудшению результатов. Выявлено наличие оптимального диапазона значений параметра, зависящего от архитектуры модели. Полученные результаты могут быть использованы при разработке и настройке систем автоматической сегментации медицинских изображений в условиях ограниченного объема обучающих данных.

Список использованных источников:

1. 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.
2. Shorten C., Khoshgoftaar T. A survey on image data augmentation for deep learning // Journal of Big Data. 2019. Vol. 6. Art. 60.
3. Kim M., Bae H.-J. Data augmentation techniques for deep learning-based medical image analyses // Journal of the Korean Society of Radiology. 2020. Vol. 81, no. 6. P. 1290–1304.
4. Dosovitskiy A., Beyer L., Kolesnikov A., et al. An image is worth 16×16 words: Transformers for image recognition at scale // arXiv. 2020. arXiv:2010.11929.
5. Liu Z., Lin Y., Cao Y., et al. Swin Transformer: Hierarchical vision transformer using shifted windows // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). 2021. P. 10012–10022.
6. Liu Z., Mao H., Wu C.-Y., Feichtenhofer C., Darrell T., Xie S. A ConvNet for the 2020s // arXiv. 2022. arXiv:2201.03545.