

Научная статья

УДК 004.8

doi: 10.17223/19988605/69/7

Нейросетевое моделирование и автоматическая сегментация корня аорты на снимках ангиографии

Ольга Михайловна Гергет¹, Никита Витальевич Лаптев², Михаил Александрович Чернявский³

¹ *Институт проблем управления им. В.А. Трапезникова Российской академии наук, Москва, Россия*

² *Сибирский государственный медицинский университет, Томск, Россия*

³ *Национальный медицинский исследовательский центр им. В.А. Алмазова, Санкт-Петербург, Россия*

¹ *olgagerget@mail.ru*

² *laptev.nv@ssmu.ru*

³ *machern@mail.ru*

Аннотация. Описан подход к решению задачи сегментации объектов исследования на снимках ангиографии при проведении процедуры транскатетерной имплантации аортального клапана (TAVI). В связи со сложностью анализа большого объема данных для кардиохирургов в статье особое внимание уделено автоматическому анализу медицинских данных, обучению и сравнению современных архитектур нейронных сетей. Подробно рассмотрены и протестированы для прогнозирования масок корня аорты 50 нейронных сетей (энкодеры U-net, U-net++, Linknet, FPN, DeepLabV3+ и декодеры Efficientnet-b0, Efficientnet-b1, Resnext50, Resnet34, Regnetx32). На этапах обучения и тестирования каскад моделей FPN + Efficientnet-b0 позволил получить наилучшую точность прогнозирования по метрикам IOU 0,771, Dice 0,870. Проведенное исследование показывает, что предложенный подход на основе нейросетевых каскадов, позволяющих идти не в сторону детектирования ключевых точек, а в направлении создания сегментационных масок, позволяет прогнозировать в реальном времени расположение аортального клапана и системы доставки, тем самым способствуя правильному позиционированию клапана во время TAVI.

Ключевые слова: сегментация; транскатетерная замена аортального клапана; глубокое обучение – CNN; анализ медицинских изображений; ангиография.

Благодарности: Работа выполнена при финансовой поддержке РФФИ в рамках научного проекта № 24-19-00084.

Для цитирования: Гергет О.М., Лаптев Н.В., Чернявский М.А. Нейросетевое моделирование и автоматическая сегментация корня аорты на снимках ангиографии // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2024. № 69. С. 64–71. doi: 10.17223/19988605/69/7

Original article

doi: 10.17223/19988605/69/7

Segmentation of the aortic root on angiography images

Olga M. Gerget¹, Nikita V. Laptev², Michael A. Chernyavsky³

¹ *V.A. Trapeznikov Institute of Control Sciences, RAS, Moscow, Russian Federation*

² *Siberian State Medical University, Tomsk, Russian Federation*

³ *National Medical Research Center named after V.A. Almazov, St. Petersburg, Russian Federation*

¹ *olgagerget@mail.ru*

² *laptev.nv@ssmu.ru*

³ *machern@mail.ru*

Abstract. The article describes an approach based on neural network modeling, which is of great interest for segmenting different anatomical structures during TAVI. Given the complexity of analyzing large volumes of data for cardiac surgeons, the article pays special attention to the automatic analysis of medical data, training, and comparison of

modern neural networks. Fifty neural networks were thoroughly examined and tested for predicting aortic root masks (encoders: U-net, U-net++, Linknet, FPN, DeepLabV3+ and decoders: Efficientnet-b0, Efficientnet-b1, Resnext50, Resnet34, Regnetx32). During the training and testing phases, the FPN Efficientnet-b0 cascade architecture demonstrated the best prediction accuracy with metrics IOU 0.771 and Dice 0.870. The conducted study shows that the proposed approach based on neural network cascades, which focuses not on detecting key points but on creating segmentation masks, allows for real-time prediction of the aortic valve and delivery system location, thereby facilitating correct valve positioning during TAVI.

Keywords: segmentation; transcatheter aortic valve replacement; deep learning – CNN; medical image analysis; aortography.

Acknowledgments: The study was financially supported by the Russian Science Foundation under scientific project No. 24-19-00084.

For citation: Gerget, O.M., Laptev, N.V., Chernyavsky, M. A. (2024) Segmentation of the aortic root on angiography images. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naja tehnika i informatika – Tomsk State University Journal of Control and Computer Science*. 69. pp. 64–71. doi: 10.17223/19988605/69/7

Введение

В связи с развитием визуального сопровождения медицинских процедур интерес к решению задачи сегментации небольших по размеру объектов на зашумленных двумерных и трехмерных данных неуклонно растет. Известные на сегодняшний день классические алгоритмы сегментации медицинских изображений [1] обладают множеством ограничений, в частности алгоритмы, построенные по принципу каскадности, обладают низкой обобщающей способностью и накапливают ошибку вычислений. Трехмерные классические алгоритмы сегментации [1] представлены достаточно малым набором исследований, что обусловлено сложностью и невозможностью сегментации трехмерных медицинских объектов в реальном времени. Большое количество классических методов автоматической сегментации сталкивается со сложностью выделения регионов на изображении в связи с неравномерностью освещения, схожими значениями интенсивности пикселей для разных объектов, малыми объемами выборок, наличием артефактов и т.д.

В настоящее время наибольшее распространение получили нейросетевые подходы при решении задачи сегментации области интереса, что в большей степени обусловлено устойчивостью к шумам, способностью выбирать (активировать) наиболее релевантные характеристические признаки без предварительной обработки, отказоустойчивостью (при неблагоприятных условиях выходная точность нейросетевой модели практически не изменяется) [2–4].

Несмотря на большое разнообразие нейросетевых архитектур (U-net [5], U-net++ [6], Linknet [7], FPN [8], DeepLabV3+ [9] и др.), позволяющих провести сегментации изображения, выделение контура корня аорты на снимках ангиографии при проведении транскатетерной имплантации аортального клапана (TAVI) [10] является нерешенной задачей. Рентгеновская коронарография включает введение контрастных веществ в коронарные сосуды, однако, несмотря на подачу контрастирующих веществ, визуализация сосудов, в частности корня аорты, сильно затруднена наличием различных шумов на изображении, низкой контрастностью, наличием неоднородностей, вызванных воздухом в легких, ограниченностью области видимости, а также быстрым вымыванием контраста из зоны интереса.

В данной работе предложено применение нейросетевого подхода при автоматической сегментации корня аорты для одиночных флюороскопических изображений (снимки ангиографии) с контрастным усилением, что позволяет использовать его как в качестве вспомогательного инструмента для визуализации с целью оптимизации позиционирования клапана, так и в качестве элемента системы для синхронизации данных КТ и снимков ангиографии.

1. Источник данных

В качестве исходных данных для обучения и валидации нейронных сетей использовались оригинальные серии изображений аортографии, собранные во время имплантации 14 саморасширяющихся биопротезов аортального клапана CoreValve пациентам со стенозом аортального клапана

в период с 2015 по 2018 г. [11] и оригинальные серии изображений аортографии, собранные во время имплантации 31 баллонорасширяемого биопротеза аортального клапана Visi-Pro пациентам со стенозом аортального клапана в период с 2020 по 2024 г., выполненные в отделении сердечно-сосудистой хирургии НИИ ФГБУ «Национальный медицинский исследовательский центр имени В.А. Алмазова» Министерства здравоохранения Российской Федерации.

Набор данных представлял собой 50 серий видеопоследовательностей размером $1\,000 \times 1\,000$ пикселей с глубиной 8 бит (шкала от 0 до 255). С целью сегментации корня аорты выбрана серия изображений с разным количеством контрастирующего вещества и в разные временные участки проведения процедуры ТАВИ. Разметка данных осуществлялась с использованием платформы Supervisely AI. Таким образом, итоговая выборка состояла из 2 250 изображений в оттенках серого, из которых 1 800 (80%) изображений использовалось в качестве обучающего набора, а 450 изображений (20%) – в качестве проверочного набора.

Разработка системы сегментации корня аорты состояла из двух основных этапов:

Этап 1. Подготовка данных: маркировка данных для разработки обучающих и проверочных наборов; аннотация изображения интервенционного кардиолога.

Этап 2. Обучение и тестирование нейронных моделей: выбор доступных архитектур нейронных сетей, функции потерь и описательных метрик, оценка качественных и количественных параметров по данным обучения и тестирования.

2. Обучение

В ходе проведения исследования использованы ключевые библиотеки, пакеты и фреймворки, в частности:

– Python версии 3.10.0 (RRID:SCR_008394) и PyCharm версии 2020.1 (RRID:SCR_018221) – в качестве основного языка программирования и интегрированной среды разработки для обработки / обработки данных и разработки нейронных сетей;

– Библиотеки Pytorch версии 2.3.1 (RRID:SCR_018536); Scikit-learn версии 0.20.3 (RRID:SCR_002577); SciPy версии 1.4.1 (RRID:SCR_008058); NumPy версии 1.18.2 (RRID:SCR_008633); Pandas версии 0.24.2 (RRID:SCR_018214); OpenCV версии 4.0.1.23 (RRID:SCR_018214); Seaborn версии 0.10.0 (RRID:SCR_018132) и Matplotlib 3.0.3 (RRID:SCR_008624).

С целью улучшения качества входной информации было предложено и применено несколько последовательных преобразований. Во-первых, реализован алгоритм вычитания из оригинального изображения результата выделения белых объектов на более темном фоне (white top-hat transformation), что позволило повысить контрастность изображения, снизить шум фона и улучшить видимость корня аорты. Необходимым для корректного отображения изображений также стал шаг, связанный с ограничением значений яркости пикселей в диапазоне [0, 255].

Во-вторых, реализован метод адаптивного выравнивания гистограммы (CLAHE) [12], что позволило регулировать контрастность локально в небольших областях изображения. Целесообразность предварительной обработки медицинских данных на основе CLAHE обусловлена многообразием структур, для которых необходимо подбирать разные коэффициенты улучшения качества отображения.

В качестве нейросетевых моделей, позволяющих извлекать признаки, в исследовании использовано несколько разновидностей энкодеров (U-net, U-net++, Linknet, FPN, DeepLabV3+) и декодеров моделей семантической сегментации (Efficientnet-b0, Efficientnet-b1, Resnext50, Resnet34, Regnetx32).

Сравнение моделей осуществлялось на базе основных характеристик эффективности, в частности сглаженного коэффициента Соренсена–Дайса (англ. DiceLoss), IoU, Precision, Recall.

Все нейронные сети обучались на компьютере с характеристиками: процессор Intel(R) Xeon(R) Gold 5218R 2,10 ГГц, 512 ГБ оперативной памяти, NVIDIA GeForce A6000 48 ГБ, Debian 11.

В качестве оптимизатора использовался RMSprop [13] с начальным шагом 0,0001 (англ. learning rate) и множителем угасания 0,9 (англ. learning rate annealing), применяющимся каждые 5 шагов. Batch size для обучения моделей был одинаковым и составлял 16 обучающих примеров.

Для оценки компонентов классификации и регрессии нейронных сетей были выбраны следующие метрики:

$$IOU = \frac{TP}{TP + FP + FN}, \quad (1)$$

$$Dice = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}, \quad (2)$$

$$Precision = \frac{TP}{TP + FP}, \quad (3)$$

$$Recall = \frac{TP}{TP + FN}, \quad (4)$$

где TP – количество истинно положительных результатов, TN – количество истинно отрицательных результатов, FP – количество ложноположительных результатов, FN – количество ложноотрицательных результатов.

3. Полученные результаты

На рис. 1 показан пример обучения исследуемых нейронных сетей на примере энкодера FPN. Графики представляют изменения значений функции потерь, пунктирными линиями выделены изменения функции потерь на тренировочном наборе данных, сплошными – на валидационном.

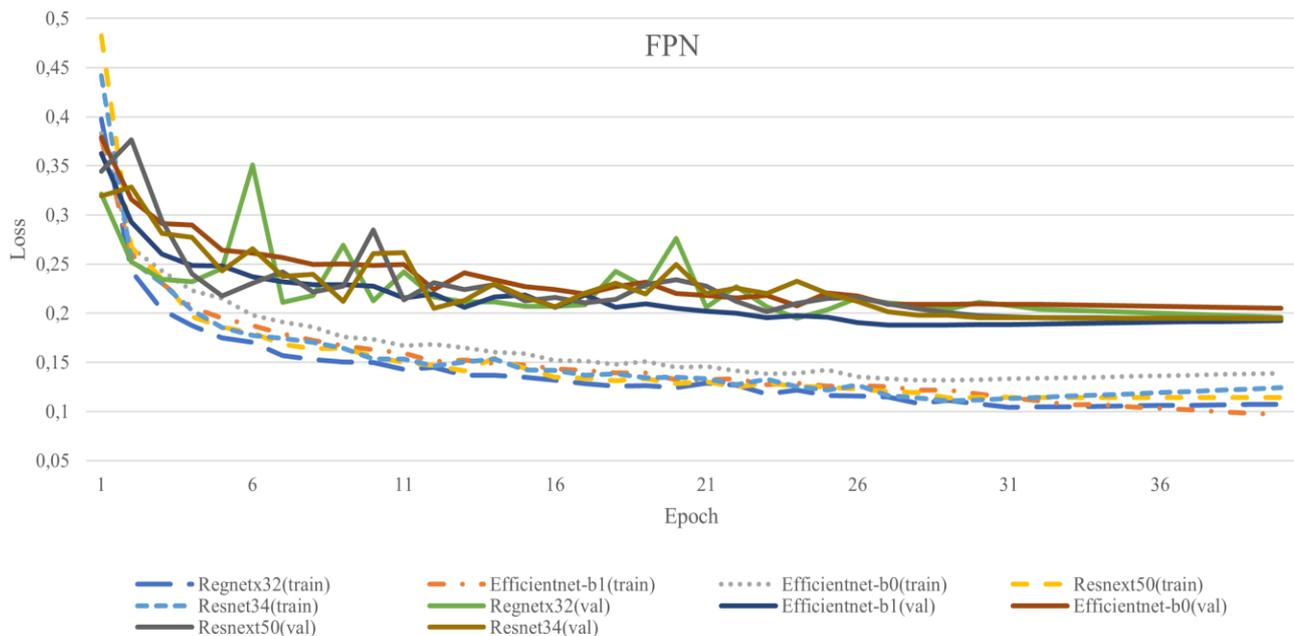


Рис. 1. Функция потерь для исследуемых нейронных сетей
Fig 1. Loss of function for saving neural networks

Результаты обучения моделей нейронных сетей представлены в таблице.

Показатели результативности нейросетевых архитектур семантической сегментации

Энкодер	Декодер	IoU	Dice	Precision	Recall	Скорость
FPN	Resnet34	0,756	0,861	0,862	0,859	0,096
	Resnext50	0,740	0,851	0,857	0,845	0,107
	Efficientnet-b0	0,771	0,870	0,833	0,911	0,101
	Efficientnet-b1	0,743	0,853	0,806	0,905	0,107
	Regnetx32	0,744	0,853	0,866	0,841	0,105

Окончание таблицы

Энкодер	Декодер	IoU	Dice	Precision	Recall	Скорость
Unet	Resnet34	0,730	0,844	0,868	0,822	0,099
	Resnext50	0,766	0,867	0,856	0,879	0,108
	Efficientnet-b0	0,755	0,861	0,848	0,873	0,105
	Efficientnet-b1	0,762	0,865	0,817	0,920	0,108
	Regnetx32	0,763	0,865	0,864	0,867	0,113
Unet++	Resnet34	0,756	0,861	0,862	0,859	0,120
	Resnext50	0,740	0,851	0,857	0,845	0,157
	Efficientnet-b0	0,738	0,849	0,867	0,832	0,117
	Efficientnet-b1	0,743	0,853	0,806	0,905	0,115
	Regnetx32	0,755	0,860	0,867	0,854	0,132
Linknet	Resnet34	0,726	0,841	0,868	0,816	0,097
	Resnext50	0,735	0,847	0,865	0,830	0,111
	Efficientnet-b0	0,753	0,859	0,826	0,894	0,107
	Efficientnet-b1	0,743	0,853	0,803	0,910	0,111
	Regnetx32	0,737	0,849	0,874	0,825	0,111
DeepLabV3+	Resnet34	0,758	0,862	0,867	0,858	0,096
	Resnext50	0,757	0,862	0,866	0,858	0,110
	Efficientnet-b0	0,761	0,864	0,827	0,905	0,106
	Efficientnet-b1	0,751	0,858	0,820	0,899	0,107
	Regnetx32	0,740	0,851	0,862	0,840	0,105
С цветовой предобработкой данных (CLAHE)						
FPN	Resnet34	0,733	0,846	0,876	0,818	0,097
	Resnext50	0,729	0,843	0,858	0,829	0,087
	Efficientnet-b0	0,745	0,854	0,825	0,885	0,096
	Efficientnet-b1	0,760	0,863	0,849	0,879	0,099
	Regnetx32	0,754	0,859	0,870	0,849	0,095
Unet	Resnet34	0,692	0,818	0,879	0,765	0,101
	Resnext50	0,735	0,847	0,885	0,812	0,102
	Efficientnet-b0	0,753	0,859	0,842	0,877	0,095
	Efficientnet-b1	0,734	0,846	0,869	0,825	0,101
	Regnetx32	0,734	0,847	0,875	0,820	0,1
Unet++	Resnet34	0,706	0,827	0,867	0,791	0,145
	Resnext50	0,705	0,827	0,878	0,782	0,148
	Efficientnet-b0	0,758	0,862	0,825	0,903	0,104
	Efficientnet-b1	0,758	0,862	0,881	0,845	0,106
	Regnetx32	0,768	0,869	0,873	0,865	0,117
Linknet	Resnet34	0,729	0,843	0,848	0,838	0,099
	Resnext50	0,703	0,826	0,774	0,886	0,101
	Efficientnet-b0	0,747	0,855	0,834	0,877	0,095
	Efficientnet-b1	0,768	0,869	0,851	0,887	0,101
	Regnetx32	0,732	0,845	0,871	0,821	0,11
DeepLabV3+	Resnet34	0,759	0,863	0,858	0,867	0,11
	Resnext50	0,737	0,848	0,845	0,852	0,124
	Efficientnet-b0	0,753	0,859	0,808	0,917	0,091
	Efficientnet-b1	0,758	0,862	0,844	0,881	0,103
	Regnetx32	0,754	0,860	0,857	0,863	0,099

Согласно результатам, представленным в таблице, наилучшие значения показателей оценки семантической сегментации корня аорты показала модель FPN Efficientnet-b0 с результатами IOU 0,771, Dice 0,870, Recall 0,833, Precision 0,911. Скорость обработки одного изображения 0,101 с. При этом необходимо отметить, что применение предобработки данных не дает значительного увеличения значений метрик качества. Однако, несмотря на отсутствие значимых различий в точности сегментации структур корня аорты, предобработанные изображения значительно улучшают визуальное восприятие изображения и облегчают разметку данных. Примеры изображений с цветовой обработкой и без обработки представлены на рис. 2.

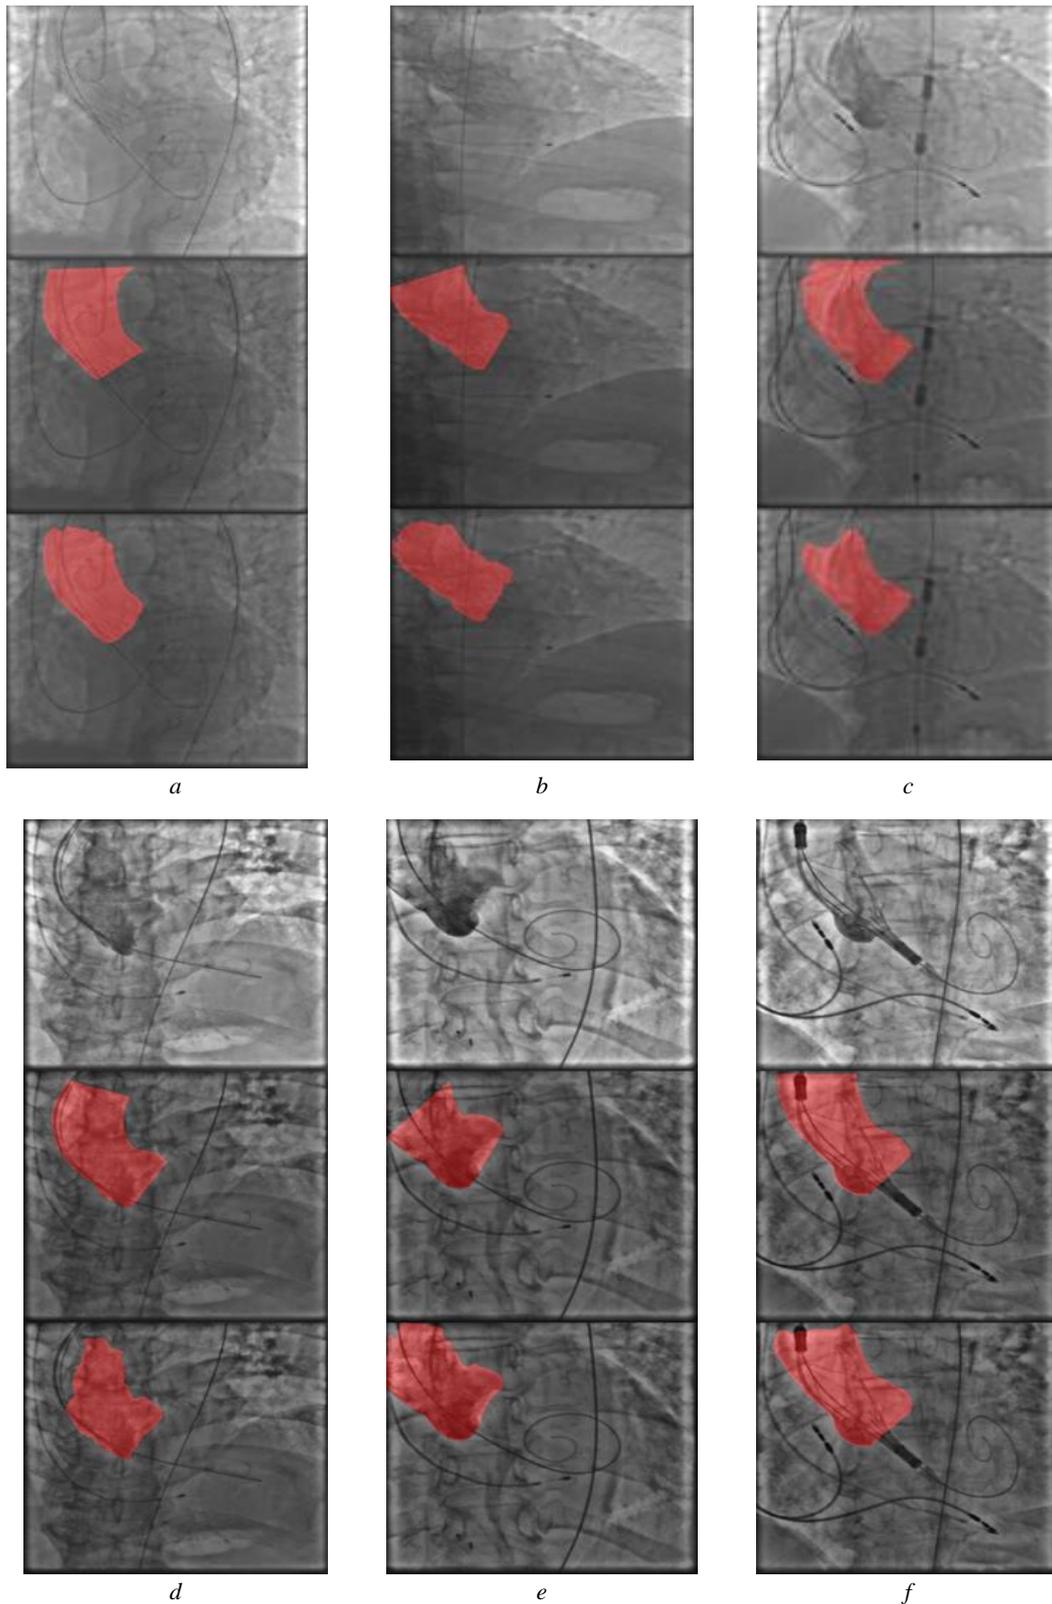


Рис. 2. Примеры сегментации корня аорты: *a–c* – сегментация изображений без цветовой обработки, изображение сверху исходное, изображение в центре с размеченной маской, изображение снизу с предсказанной маской, *d–f* – сегментация изображений с цветовой обработкой (CLANE), изображение сверху исходное, изображение в центре с размеченной маской, изображение снизу с предсказанной маской

Fig. 2. Examples of segmentation of the lower aorta: *a–c* image segmentation without color processing, top image is original, center image with labeled mask, image usually with predicted mask, *d–f* image segmentation with color processing (CLANE), top image is original, center image with labeled mask, the image matches the predicted mask

Заключение

В статье приведен анализ 50 серий видеопоследовательностей, полученных при проведении транскатетерной имплантации аортального клапана, с целью создания системы визуальной помощи для кардиохирурга.

Поскольку реальные данные имеют низкую разрешающую способность, применение известных методов детектирования как с предобработкой входных данных, так и при ее отсутствии не позволяет получить приемлемое качество визуального представления корня аорты на данных с малым количеством контрастирующего вещества. Однако применение каскада нейросетевых архитектур дало возможность получать сегментационные маски и использовать их в качестве ориентира, что позволило визуализировать корень аорты при снижении количества введений контрастирующего вещества во время проведения операции.

Реализация и сравнение различных каскадов архитектур энкодер–декодер, где в качестве энкодера выбраны Unet, Unet++, Linknet, FPN, DeepLabV3+, а в качестве декодера выступают модели EfficientNet-b0, EfficientNet-b1, Resnext50, Resnet34, Regnetx32, позволили выделить с точки зрения точности оптимальную нейросетевую модель для решения задачи распознавания и сегментации контуров корня аорты во время проведения процедуры TAVI. Наилучшим каскадом является FPN Efficientnet-b0. Показатели результативности проведения семантической сегментации в данном случае имеют значения: IOU 0,771, Dice 0,870, Recall 0,833, Precision 0,911, Скорость обработки одного изображения 0,101 с. Модель на основе данной архитектуры (FPN + декодер Efficientnet-b0) может использоваться как в качестве вспомогательного инструмента для оптимизации позиционирования клапана, так и в качестве элемента системы для синхронизации данных КТ и снимков ангиографии.

Список источников

1. Ramesh K.K.D., Kiran Kumar G., Swapna K., Datta D., Suman Rajest S. A review of medical image segmentation algorithms // EAI Endorsed Transactions on Pervasive Health and Technology. 2021. V. 7 (27). Art. e6. doi: 10.4108/eai.12-4-2021.169184
2. Li Y., Wu Y., He J., Jiang W., Wang J., Peng Y., Chen M. Automatic coronary artery segmentation and diagnosis of stenosis by deep learning based on computed tomographic coronary angiography // European Radiology. 2022. V. 32 (9). P. 6037–6045. doi: 10.1007/s00330-022-08761-z
3. Popov M., Amanturdieva A., Zhaksylyk N., Alkanov A., Saniyazbekov A., Aymyshev T. et al. Dataset for Automatic Region-based Coronary Artery Disease Diagnostics Using X-Ray Angiography Images // Scientific Data. 2024. V. 11 (1). Art. 20. doi: 10.1038/s41597-023-02871-z
4. Zhu X., Cheng Z., Wang S., Chen X., Lu G. Coronary angiography image segmentation based on PSPNet // Computer Methods and Programs in Biomedicine. 2021. V. 200. Art. 105897. doi: 10.1016/j.cmpb.2020.105897
5. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015). 5–9 October, Munich, Germany. 2015. P. 234–241.
6. Zhou Z., Rahman Siddiquee M.M., Tajbakhsh N., Liang J. Unet++: A nested u-net architecture for medical image segmentation // Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop (DLMIA 2018). 20 September, Granada, Spain. 2018. P. 3–11. doi: 10.1007/978-3-030-00889-5_1
7. Chaurasia A., Culurciello E. Linknet: Exploiting encoder representations for efficient semantic segmentation // 2017 IEEE Visual Communications and Image Processing (VCIP). 2017. P. 1–4.
8. Martinsson J., Mogren O. Semantic segmentation of fashion images using feature pyramid networks // Proc. 2019 International Conference on Computer Vision Workshop (ICCVW 2019). 2019. doi: 10.1109/ICCVW.2019.00382
9. Baheti B., Innani S., Gajre S., Talbar S. Semantic scene segmentation in unstructured environment with modified DeepLabV3+ // Pattern Recognition Letters. 2029. V. 138. P. 223–229.
10. Abdelgawad A., Hussein M.A., Naeem H., Abuellata R., Alghamdy S. A comparative study of TAVR versus SAVR in moderate and high-risk surgical patients: Hospital outcome and midterm results // Heart Surgery Forum. 2019. V. 22 (5). P. E331–E339. doi: 10.1532/hfsf.2243.
11. The repository of the Research Laboratory for Processing and Analysis of Big Data (Tomsk Polytechnic University). URL: https://www.dropbox.com/sh/80wpfkdbhuo019/AADuysNg3sO00_vjhW8MgZ6Ba?dl=0 (accessed: 10.05.2024).
12. Pisano E.D., Zong S., Hemminger B.M., DeLuca M., Johnston R.E., Muller K. et al. Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms // Journal of Digital Imaging. 1998. V. 11. P. 193–200. doi: 10.1007/BF03178082
13. RMSprop // Keras. URL: <https://keras.io/api/optimizers/rmsprop/> (accessed: 10.05.2024).

References

1. Ramesh, K.K.D., Kiran Kumar, G., Swapna, K., Datta, D. & Suman Rajest, S. (2021) A review of medical image segmentation algorithms. *EAI Endorsed Transactions on Pervasive Health and Technology*. 7(27). DOI: 10.4108/eai.12-4-2021.169184
2. Li, Y., Wu, Y., He, J., Jiang, W., Wang, J., Peng, Y. & Chen, M. (2022). Automatic coronary artery segmentation and diagnosis of stenosis by deep learning based on computed tomographic coronary angiography. *European Radiology*. 32(9). pp. 6037–6045. DOI: 10.1007/s00330-022-08761-z
3. Popov, M., Amanturdieva, A., Zhaksylyk, N., Alkanov, A., Saniyazbekov, A., Aimyshev, T. et al. (2024) Dataset for Automatic Region-based Coronary Artery Disease Diagnostics Using X-Ray Angiography Images. *Scientific Data*. 11(1). pp. 20. DOI: 10.1038/s41597-023-02871-z
4. Zhu, X., Cheng, Z., Wang, S., Chen, X. & Lu, G. (2021). Coronary angiography image segmentation based on PSPNet. *Computer Methods and Programs in Biomedicine*. 200. DOI: 10.1016/j.cmpb.2020.105897
5. Ronneberger, O., Fischer, P. & Brox, T. (2015) U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015)*. October 5–9, 2015. Munich. Germany. pp 234–241.
6. Zhou, Z., Rahman Siddiquee, M.M., Tajbakhsh, N. & Liang, J. (2018) Unet++: A nested u-net architecture for medical image segmentation. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. 4th International Workshop (DLMIA 2018). September 20. Granada. Spain. pp. 3–11. DOI: 10.1007/978-3-030-00889-5_1
7. Chaurasia, A. & Culurciello, E. (2017) Linknet: Exploiting encoder representations for efficient semantic segmentation. *2017 IEEE Visual Communications and Image Processing (VCIP)*. pp. 1–4.
8. Martinsson, J. & Mogren, O. (2019) Semantic segmentation of fashion images using feature pyramid networks. *Proceedings – 2019 International Conference on Computer Vision Workshop (ICCVW 2019)*. DOI: 10.1109/ICCVW.2019.00382
9. Baheti, B., Innani, S., Gajre, S. & Talbar, S. (2020) Semantic scene segmentation in unstructured environment with modified DeepLabV3+. *Pattern Recognition Letters*. 138. pp. 223–229.
10. Abdelgawad, A., Hussein, M.A., Naeem, H., Abuellata, R. & Alghamdy, S. (2019) A comparative study of TAVR versus SAVR in moderate and high-risk surgical patients: Hospital outcome and midterm results. *Heart Surgery Forum*. 22(5). pp. E331–E339. DOI: 10.1532/hcf.2243
11. Tomsk Polytechnic University. (n.d.) *The dataset presented in this study can be found in the repository of the Research Laboratory for Processing and Analysis of Big Data (Tomsk Polytechnic University)*. [Online] Available from: https://www.dropbox.com/sh/80wpfkdbhuo019/AADuysNg3sO00_vjhW8MgZ6Ba?dl=0 (Accessed: 10th May 2024).
12. Pisano, E.D., Zong, S., Hemminger, B.M., DeLuca, M., Johnston, R.E., Muller, K., et al. (1998). Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms. *Journal of Digital Imaging*. 11. pp. 193–200. DOI: 10.1007/BF03178082
13. *Keras*. [Online] Available from: <https://keras.io/api/optimizers/rmsprop/> (Accessed: 10th May 2024).

Информация об авторах:

Гергет Ольга Михайловна – доктор технических наук, ведущий научный сотрудник Института проблем управления им. В.А. Трапезникова Российской академии наук (Москва, Россия). E-mail: olgagerget@mail.ru

Лаптев Никита Витальевич – научный сотрудник отдела медицинских данных и биоинформатики Сибирского государственного медицинского университета (Томск, Россия). E-mail: raa@mail.tsu.ru

Чернявский Михаил Александрович – доктор медицинских наук, доцент кафедры факультетской хирургии с клиникой, заведующий НИО сосудистой и интервенционной хирургии Национального медицинского исследовательского центра им. В.А. Алмазова» Минздрава России (Санкт-Петербург, Россия). E-mail: machern@mail.ru

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Information about the authors:

Gergert Olga M. (Doctor of Technical Sciences, Leading Researcher Laboratory №80, V.A. Trapeznikov Institute of Control Sciences, RAS, Moscow, Russia). E-mail: olgagerget@mail.ru

Laptev Nikita V. (Researcher at the Department of Medical Data and Bioinformatics of Siberian State Medical University, Tomsk, Russia). E-mail: laptev.nv@ssmu.ru

Chernyavsky Michael A. (Doctor of Medical Sciences, Associate Professor of Department of Faculty Surgery with Clinic, Head of Vascular and Endovascular surgery Department, Almazov National Medical Research Center, Saint-Petersburg, Russia). E-mail: machern@mail.ru

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.

Поступила в редакцию 08.07.2024; принята к публикации 02.12.2024

Received 08.07.2024; accepted for publication 02.12.2024