

ХИБРИДНИ СИСТЕМИ С ИЗКУСТВЕН ИНТЕЛЕКТ ЗА РАЗПОЗНАВАНЕ НАОБРАЗИ И ПОДПОМАГАНЕ НА ДИАГНОСТИЧНИЯ ПРОЦЕС ПРИ ЗАБОЛЯВАНИЯ НА АОРТАТА

Даниел Стоянов, Сотир Сотиров, Владимир Корновски

Бургаски държавен университет „Проф. д-р Асен Златаров“, бул. „Проф. Якимов“1, Бургас
8010, България

e-mails: daniel-stoyanov@uniburgas.bg, ssotirov@btu.bg, vladimir-
kornovski@hotmail.com

Резюме: *Острите аортни патологии, по-специално дисекациите и аневризмите, представляват животозастрашаващи състояния, изискващи бърза и прецизна диагноза. Традиционният ръчен анализ на изображения от компютърна томография (КТ) често е съпроводен със субективизъм и вариабилност. Целта на настоящото изследване е създаването на хибридна система с изкуствен интелект за автоматизиран морфометричен анализ, която да служи като надежден дигитален асистент в клиничното вземане на решения. Методологията интегрира класически алгоритми за компютърно зрение със съвременни дълбоки конволюционни невронни мрежи (U-Net архитектура) в рамките на философия, фокусирана върху качеството на данните (data-centric). Резултатите от разработения прототип показват успешна семантична сегментация на аортни лумени и интимални ламели, както и елиминиране на често срещани КТ артефакти. Изводите подчертават, че в ранния етап на разработка приоритет трябва да бъде качеството на аотираните данни, а системата трябва да допълва, а не да заменя лекаря, допринасяйки за ефективното сътрудничество между човек и изкуствен интелект в образната диагностика.*

Ключови думи: аортни патологии, компютърна томография, изкуствен интелект, семантична сегментация, анализ на медицински изображения.

HYBRID ARTIFICIAL INTELLIGENCE SYSTEMS FOR IMAGE RECOGNITION AND SUPPORT OF THE DIAGNOSTIC PROCESS IN AORTIC DISEASES

Daniel Stoyanov, Sotir Sotirov, Vladimir Kornovski

Burgas State University „Prof. Dr. Asen Zlatarov“, Prof. Yakimov Blvd. No. 1,
8010, Burgas, Bulgaria

e-mails: daniel-stoyanov@uniburgas.bg, ssotirov@btu.bg, vladimir-
kornovski@hotmail.com

Abstract: *Acute aortic pathologies, particularly dissections and aneurysms, are life-threatening conditions that require rapid and precise diagnosis. Traditional manual analysis of computed tomography (CT) images is often associated with subjectivity and variability. The aim of the present study is to develop a hybrid artificial intelligence system for automated morphometric analysis that can serve as a reliable digital assistant in clinical decision-making. The methodology integrates classical computer vision algorithms with modern deep convolutional neural networks (U-Net architecture) within a data-centric philosophy focused on data quality. The results obtained from the developed prototype demonstrate successful semantic segmentation of aortic lumens and intimal flaps, as well as the elimination of common CT artifacts. The conclusions emphasize that, at an early stage of development, priority should be given to the quality of annotated data, and that the*

system should complement rather than replace the physician, contributing to effective human–artificial intelligence collaboration in medical imaging diagnostics.

Keywords: aortic pathologies, computed tomography, artificial intelligence, semantic segmentation, medical image analysis.

1. Въведение

Острите аортни синдроми, обхващащи аортна дисекция, интрамурален хематом и пенетрираща аортна язва, представляват медицински спешни състояния с изключително висок риск за пациента. Смъртността при тези заболявания може да надхвърли 1% на час в острата фаза, ако не се приложи своевременно лечение [1][2]. Аортните дисекции засягат приблизително 3 случая на 100 000 души население годишно [3], като класификацията им по системите на Станфорд и ДеБейки е определяща за терапевтичния подход [14][15].

Диагностиката на тези състояния се основава предимно на многодетекторна компютърна томографска ангиография (КТА), която е утвърдена като златен стандарт в международните насоки [4][5]. Въпреки високата разделителна способност на съвременната апаратура [16], настоящият диагностичен процес среща сериозни предизвикателства. Ръчното измерване на аортните размери и анализът на морфологията в множество КТ срезове е процес, съпроводен със субективизъм и значителна вариабилност между различните наблюдатели [6][7]. Това създава диагностична несигурност, особено в гранични случаи, и затруднява стандартизацията на лечението [8][9].

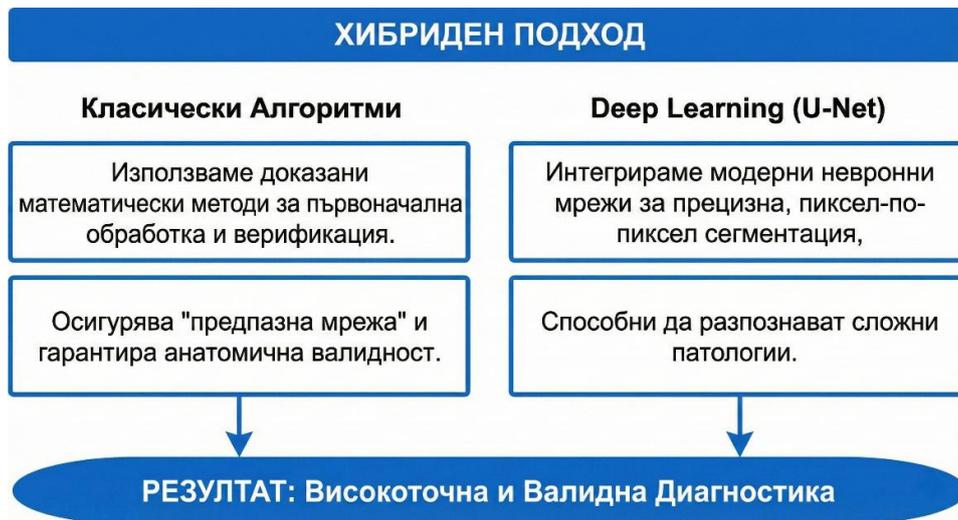
Допълнителен проблем представляват ограниченията във времето в условията на спешност. Всяко забавяне при остра дисекция тип А увеличава риска от смъртност [10], а ръчният морфометричен анализ изисква технологично време и специализирана експертиза. Често срещаните образни артефакти, като движение на сърцето или втвърдяване на лъча от импланти, допълнително усложняват интерпретацията на данните.

В отговор на тези проблеми, последните постижения в дълбокото обучение (Deep Learning) и конволюционните невронни мрежи (КНМ) демонстрират значителен потенциал за автоматизация в анализа на медицински изображения [11][12]. Тези технологии вече показват резултати, сравними с човешките, в области като откриване на пневмония или онкологични лезии [13]. Приложението им при аортна патология обаче изисква специфичен подход, който да преодолее ограниченията на чисто алгоритмичните решения и да осигури надеждност в клинична среда.

2. Цел, задачи и методи на проучването

Основната цел на изследването е създаването и валидирането на хибридна система с изкуствен интелект, която да подпомага диагностичния процес при заболявания на аортата чрез автоматизиран морфометричен анализ. Задачите включват разработване на модул за предварителна обработка на изображения, внедряване на дълбока невронна мрежа за семантична сегментация и интегриране на алгоритми за класическо компютърно зрение за валидация на резултатите. Подходът се базира на философията „човек в цикъла“ (human-in-the-loop), където системата функционира като асистент, а не като автономен диагностик.

Методологичната рамка интегрира три функционални компонента. Първият е модул за предварителна обработка, който стандартизира DICOM изображенията чрез нормализация на единиците на Хаунсфийлд и прилага морфологични операции за потискане на артефакти и подобряване на ръбовете. Този процес подготвя данните както за класическите алгоритми, така и за невронната мрежа.

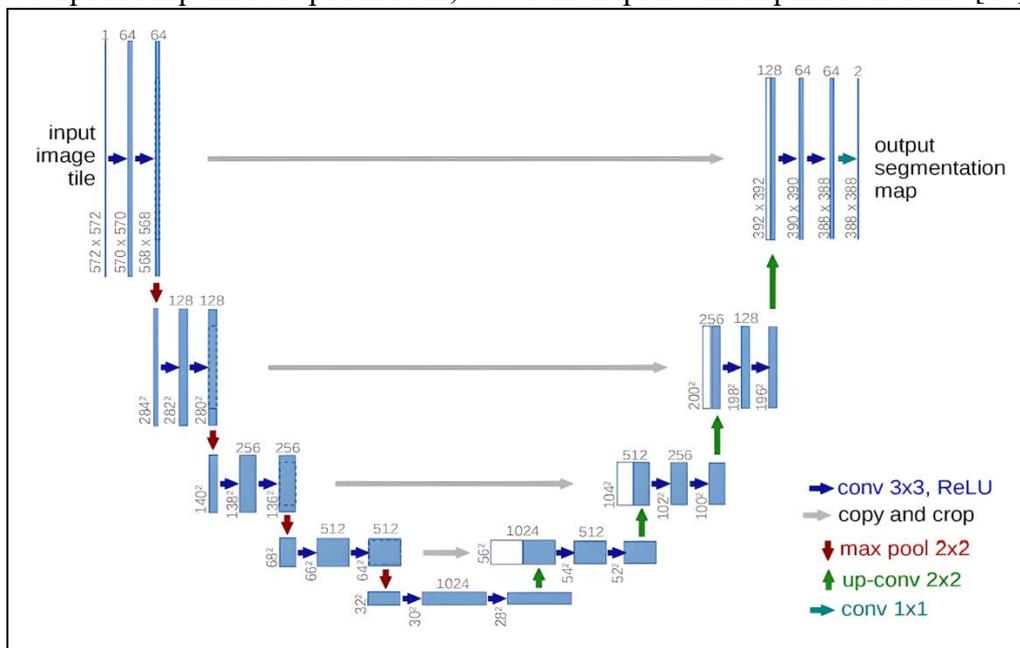


Фиг. 1. Конвейер за предварителна обработка на изображения с паралелни класически и дълбоко-обучащи анализни пътища

За основната задача по сегментиране се използва архитектурата U-Net [17], която е де факто стандарт в медицинското изобразяване [18]. Мрежата се състои от енкодер за извличане на характеристики и декодер за възстановяване на пространствената разделителна способност. За обучение на модела се прилага функция на загубата „Dice Loss“, избрана заради устойчивостта ѝ към дисбаланс на класовете, тъй като аортният лумен заема малка част от всеки срез.

$$L_{Dice} = 1 - \frac{2 \sum_i X_i Y_i}{\sum_i X_i + \sum_i Y_i} \quad (1)$$

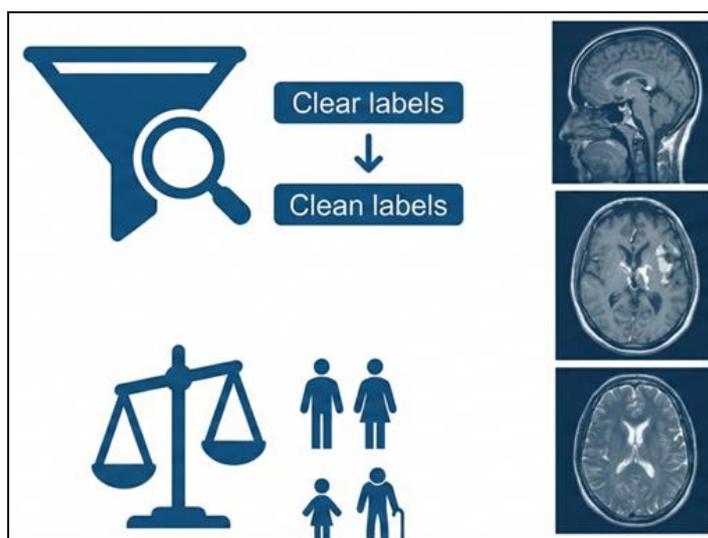
където X_i са прогнозираните вероятности, а Y_i е експертно анотираната истина [19][20].



Фиг. 2. Архитектура на семантична сегментация на U-Net за очертаване на аортния лумен

Третият компонент е стратегията за управление на данните. Приоритет се дава на качеството на анотираните данни пред алгоритмичната сложност. Използвани са ретроспективни КТ ангиографски изследвания, които преминават през строг протокол за

анотиране и стратификация по демографски признаци и патология, за да се избегнат статистически отклонения [21][22].

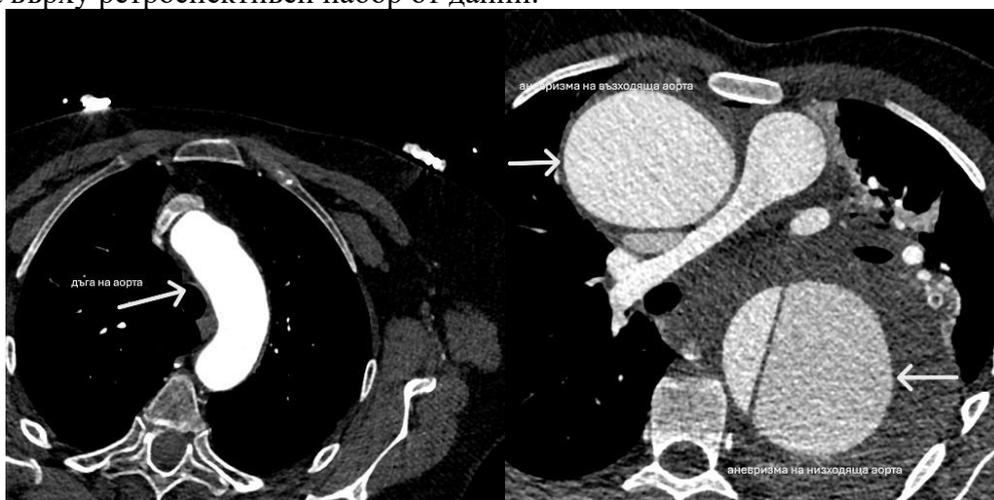


Фиг. 3. Многоинституционален процес на обработка на данни, наблягащ на качеството и представителността

Обучението на системата се извършва чрез разделяне на данните на тренировъчен (70%), валидационен (15%) и тестов (15%) набор, като се прилагат техники за допълване на данни (data augmentation) като ротации и еластични деформации за подобряване на обобщаващата способност на модела.

3. Резултати и обсъждане

В рамките на настоящия етап на доказване на концепцията бе извършена оценка на прототипа върху ретроспективен набор от данни.



Фиг. 4. Представителни аксиални КТ срезове от използвания набор данни: (ляво) Анатомия на аортната дъга; (дясно) Патология с аневризми на възходящата и низходящата аорта

Първоначалните резултати демонстрират техническа осъществимост на автоматизираната сегментация, но същевременно разкриват сериозни предизвикателства, присъщи на работата с медицински изображения. При тестовия набор се наблюдава, че макар архитектурата U-Net успешно да локализира основните аортни структури, моделът е склонен към генериране на фалшиво позитивни резултати. Често срещан проблем при моделите тип „черна кутия“ е объркването на аортната тъкан с други високоплътни структури, като кости или калцификати, особено в случаите с вариращо качество на изображението.

Този проблем налага внедряването на защитни механизми чрез т.нар. „хибридна сигурност“ (Post-Processing). Както е илюстрирано в работния процес на системата, суровият изход от невронната мрежа преминава през класически филтри за компютърно зрение, по-конкретно анализ на свързаните компоненти (Connected Components Analysis). Този етап е критичен за елиминиране на шум и обекти с анатомично невъзможна топология, с което се гарантира, че крайният визуален резултат е преминал през морфологична верификация, осигуряваща необходимата за лекарите интерпретируемост [23].



Фиг. 5. Алгоритъм на работния процес на прототипа: от входно изображение до автоматизиран анализ и извличане на метрики

Анализът на грешките, включително отклоненията в контурите на аортната дъга и границите на лумена, потвърждава основната теза на изследването, че ефективността на AI модела е пряка функция на качеството на данните, а не само на алгоритмичната сложност, принцип, известен като data-centric AI [25]. Наблюдаваните неточности при сегментацията в граничните зони се дължат на липсата на достатъчно хетерогенен и балансиран набор от данни (Dataset) в текущия прототип. За да се избегнат статистически отклонения (Bias) [21][22] и да се постигне надеждна клинична интерпретация, включваща трансформация от пикселно пространство в милиметри чрез DICOM метаданни, е необходимо мащабно разширяване на базата данни с експертна анотация.

Сравнителният анализ между ръчните и автоматизираните измервания показва корелация, която е обещаваща за скринингови цели, но все още недостатъчна за автономна диагностика. Пътната карта за развитие предвижда преход към обучение с „големи данни“ (Big Data), което да минимизира влиянието на артефактите и да позволи прецизна пространствена калибрация, необходима за интраоперативно планиране.

4. Изводи

Настоящото изследване демонстрира успешното създаване на прототип (Proof of Concept) на система за подпомагане на диагностиката при аортна патология. Основният извод от експерименталната част е, че самостоятелното използване на дълбоки невронни мрежи (като U-Net) е недостатъчно за клинични цели поради риска от фалшиво позитивни резултати. Именно интегрирането на класически методи за компютърно зрение в пост-обработката („хибридна сигурност“) се явява критичният фактор, който позволява елиминиране на халюцинациите и гарантира анатомична валидност на сегментацията.

Анализът на грешките потвърди категорично, че качеството и представителността на данните са по-определящи за успеха, отколкото алгоритмичната сложност – принцип, залегнал във философията на data-centric AI. Наблюдаваните отклонения в граничните зони на аортата подчертават необходимостта от прецизна експертна анотация и балансиране на наборите от данни спрямо различни анатомични вариации и качество на сканиране.

Въпреки обещаващата техническа осъществимост, системата се намира в ранен етап на развитие. Бъдещата работа изисква преход към обучение с големи масиви от данни („Big Data“) [24] за минимизиране на статистическите отклонения и постигната на прецизна

пространствена калибрация. Крайната цел не е създаването на автономен диагностик, а установяването на ефективно сътрудничество, при което изкуственият интелект функционира като надежден, но контролиран от лекаря инструмент за бърз морфометричен анализ.

Благорности

Докладът се финансира по проект BG16RFPR002-1.014-0004 - Център за върхови постижения „Университети за наука, информатика и технологии в е-обществото“ (УНИТе), финансиран от Програма "Научни изследвания, иновации и дигитализация за интелигентна трансформация“ 2021-2027 г., съфинансирана от Европейския съюз.

Библиография

1. Hiratzka, L. F., Bakris, G. L., Beckman, J. A., et al. (2010). 2010 ACCF/AHA/AATS Guidelines for the Diagnosis and Management of Aortic Disease. *Journal of the American College of Cardiology*, 55(27), e27–e129.
2. Mussa, F. F., Horton, J. D., Moridzadeh, R., Nicholson, J., & Azizzadeh, A. (2016). Acute Aortic Dissection and Intramural Hematoma: A Systematic Review. *Journal of the American Medical Association*, 316(7), 754–763.
3. Booher, A. M., Isselbacher, E. M., Nienaber, C. A., et al. (2011). The IRAD classification system for type B aortic dissection. *American Journal of Cardiology*, 107(6), 911–917.
4. Erbel, R., Aboyans, V., Boileau, C., et al. (2014). 2014 ESC Guidelines on the diagnosis and treatment of aortic diseases. *European Heart Journal*, 35(41), 2873–2926.
5. Gutierrez, A., Erbel, R., & Aboyans, V. (2018). Imaging in aortic disease: current standards and future directions. *European Heart Journal – Cardiovascular Imaging*, 19(7), 719–721.
6. Evangelista, A., Mussa, F., & Nienaber, C. A. (2015). Imaging in acute aortic dissection: State-of-the-art review. *Journal of the American College of Cardiology*, 65(4), 349–361.
7. Azari, B., Mehregan, K., Kharazian, Z., et al. (2020). Inter-observer variability in measuring aortic root diameter and association with outcomes. *International Journal of Cardiovascular Imaging*, 36(4), 631–639.
8. Pape, L. A., Awais, M., Woznicki, E. M., et al. (2015). Presentation, Diagnosis, and Outcomes of Acute Aortic Dissection: 17-Year Trends From the International Registry of Acute Aortic Dissection. *Circulation*, 132(13), 1255–1262.
9. Rizzo, J. A., Plappert, T., & Woo, E. Y. (1998). Trends in mortality, morbidity, and resource utilisation in acute type A aortic dissection. *Circulation*, 99(14), 1853–1857.
10. Rizzo, J. A., Aranki, S. F., Aklog, L., et al. (1998). Rapid diagnosis and treatment of type A aortic dissection. *Circulation*, 98(Suppl 19), II-274–II-279.
11. Litjens, G., Kooi, T., Bejnordi, B. E., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88.
12. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
13. Esteva, A., Kuprel, B., Novoa, R. A., et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118.
14. Daily, P. O., Trueblood, H. W., Stinson, E. B., et al. (1970). Management of acute aortic dissections. *Annals of Thoracic Surgery*, 10(3), 237–247.
15. DeBaKey, M. E., Henly, W. S., Cooley, D. A., et al. (1965). Surgical management of aortic dissection. *Journal of Thoracic and Cardiovascular Surgery*, 51(1), 114–133.
16. Erbel, R., Aboyans, V., Boileau, C., et al. (2014). 2014 ESC Guidelines on the diagnosis and treatment of aortic diseases. *European Heart Journal*, 35(41), 2873–2926.
17. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *MICCAI 2015* (pp. 234–241). Springer.
- 18] Siddique, N., Paheding, S., Elkin, C. P., & Devabhaktuni, V. (2021). U-Net and its variants for medical image segmentation: A review. *Journal of Imaging*, 7(3), 55.

19. Dice, L. R. (1945). Measures of the amount of ecologic association between species. *Ecology*, 26(3), 297–302.
20. Sudre, C. H., Li, W., Vercauteren, T., Ourselin, S., & Cardoso, M. J. (2017). Generalised Dice overlap as a deep learning loss function for highly unbalanced segmentations. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support* (pp. 240–248). Springer.
21. Buolamwini, J., & Gebru, T. (2018). Gender shades: Intersectional accuracy disparities in commercial gender classification. In *Conference on Fairness, Accountability and Transparency* (pp. 77–91).
22. Gianfrancesco, M. A., Tamang, S., Yazdany, J., & Schmajuk, G. (2018). Potential biases in machine learning algorithms using electronic health record data. *JAMA Internal Medicine*, 178(11), 1544–1547.
23. Montavon, G., Samek, W., & Müller, K. R. (2018). Methods for interpreting and understanding deep neural networks. *Digital Signal Processing*, 73, 1–15.
24. Beam, A. L., Kohane, I. S., & Drazen, J. M. (2018). Big data and machine learning in health care. *JAMA*, 319(13), 1317–1318.
25. Ng, A. (2021). MLOps: From model-centric to data-centric AI. Landing AI white paper.