

Чабан О.Р., Манзюк Е.А. (Хмельницький національний університет, м. Хмельницький, Україна)

ПІДХІД ДО ІНТЕГРУВАННЯ ЕКСПЕРТНИХ ЗНАТЬ В МОДЕЛЬ U-NET ДЛЯ СЕГМЕНТУВАННЯ ЗОБРАЖЕНЬ МРТ СЕРЦЯ

Анотація: У статті запропоновано новий підхід до інтегрування експертних знань медичних фахівців у нейронну мережу архітектури U-Net для сегментування зображень МРТ серця. Запропонований підхід передбачає використання механізмів уваги, керованих експертними анотаціями, та впровадження анатомічних обмежень через спеціалізовані функції втрат. Це дає змогу покращити здатність мережі створювати анатомічно точні та клінічно значущі сегментовані маски на зображенні МРТ серця. Підхід включає декілька послідовних етапів, зокрема, аугментацію даних з експертними анотаціями, проєктування механізму уваги та додання функцій втрат із врахуванням анатомічних обмежень. Експериментальні результати за набором даних Automated Cardiac Diagnosis Challenge у задачі сегментування продемонстрували покращення проти базової моделі U-Net за низкою метрик сегментації.

Ключові слова: інтеграція експертних знань, нейронна мережа, U-Net, сегментація, МРТ серця, механізм уваги, анатомічні обмеження, функції втрат, аугментація даних, Automated Cardiac Diagnosis Challenge.

Abstract: This study presents a novel method for integrating expert domain knowledge from healthcare professionals into a U-Net-type neural network for cardiac MRI segmentation. By incorporating attention mechanisms guided by expert annotations and enforcing anatomical constraints through specialized loss functions, our approach enhances the network's ability to produce anatomically accurate and clinically meaningful segmentations. The proposed method is detailed in several sequential steps, including data augmentation with expert annotations, the design of an attention mechanism, and the incorporation of anatomical constraint loss functions. Experimental results on the Automated Cardiac Diagnosis Challenge dataset demonstrate significant improvements over the baseline U-Net model across several segmentation metrics.

Keywords: integration of expert knowledge, neural network, U-Net, segmentation, cardiac MRI, attention mechanism, anatomical constraints, loss functions, data augmentation, Automated Cardiac Diagnosis Challenge.

Вступ.

Магнітно-резонансна томографія (МРТ) серця є основним інструментом у процесі діагностування та лікування серцево-судинних захворювань. Вона забезпечує деталізоване зображення структур серця без іонізуючого випромінювання. Точне сегментування зображень МРТ серця є важливою для кількісного оцінювання функції серця, аналізу життєздатності міокарда та планування втручань [1]. Згорткові нейронні мережі (CNN), зокрема архітектура U-Net [2], показали високі результати в задачах сегментування медичних зображень [3]. Однак ці моделі часто працюють без явного інтегрування експертних знань медичних фахівців [4, 5], що може обмежувати їхню здатність створювати анатомічно достовірні та клінічно правдиві сегментовані маски.

Медичні фахівці володіють експертним глибоким знанням щодо анатомії серця, патологій та клінічного значення певних ознак на зображеннях. Інтегрування цих знань у моделі глибокого навчання може значно підвищити їхню продуктивність, особливо у випадках зі складною анатомією чи артефактами [6, 7]. Сучасні підходи, як от механізми уваги [8] та функції втрат з анатомічними обмеженнями [9], дають перспективи для впровадження експертного досвіду в нейронні мережі [10].

У цій роботі запропоновано новий підхід до інтегрування експертних знань у нейронну мережу типу U-Net для сегментування зображень МРТ серця. Наш підхід використовує механізми уваги, керовані експертними анотаціями, для фокусування мережі на клінічно важливих областях, а також включає анатомічні обмеження у функції втрат для забезпечення реалістичних сегментацій.

Запропонований підхід.

Запропонований підхід до інтегрування експертних знань у нейронну мережу включає кілька послідовних етапів, що покликані забезпечити результативну та успішну інтеграцію експертних знань.

Блок 1. Аугментація даних з експертними анотаціями

Крок 1.1. Збір експертних анотацій

Медичні фахівці надають анотації, що виділяють області інтересу (ROI) на зображеннях МРТ серця, як от лівий шлуночок (LV), правий шлуночок (RV) і міокард, включно з областями інтересу (ROI) МРТ серця, що схильні до помилок сегментування через патології або артефакти.

Крок 1.2. Аугментація навчальних даних

Експертні анотації використовуються для створення додаткових каналів у вхідних даних, що дає змогу мережі навчатися як за вхідними зображеннями, так і за областями МРТ, що виділені експертами.

Блок 2. Механізм уваги за експертним знанням

Крок 2.1. Інтеграція механізмів уваги

Архітектура U-Net модифікована через додавання порогів уваги (attention gates) у з'єднаннях із пропуском (skip connections). Ці пороги отримують мапи ознак з енкодера та ROI-дані від експертів, формуючи коефіцієнти уваги, що виділяють важливі області.

Нехай X_i – вхідна мапа ознак на 1-ому шарі, а G – сигнал-напряв від експертних анотацій. Коефіцієнт уваги α обчислюється за формулою:

$$\alpha_i = \sigma(W^T [X_i, G] + b),$$

де W і b – ваги, значення яких визначаються під час навчання нейронної мережі, $[\cdot, \cdot]$ – конкатенація, а σ – сигмоїдна активаційна функція.

Крок 2.2. Модуляція мап ознак

Коефіцієнти уваги модулюють мапи ознак:

$$\tilde{X}_i = \alpha_i \square X_i,$$

де \square – покомпонентне множення.

Наведена вище модуляція мап ознак має на меті фокусувати увагу мережі на регіонах, які експерти вважають важливими.

Блок 3. Впровадження функцій втрат з анатомічними обмеженнями

Крок 3.1. Визначення анатомічних співвідношень

На основі експертних знань подамо такі анатомічні обмеження:

1. Міокард мусить повністю охоплювати порожнину LV.
2. Порожнина RV має бути прилеглою до міокарда.
3. Неприпустиме перекриття структур, які не є сусідніми.

Крок 3.2. Функції втрат для анатомічних обмежень

Нижче формалізуємо функції втрат, що спроектовані виключно для усунення поданих вище обмежень:

– функція втрат охоплення, L_{enc} :

$$L_{\text{enc}} = \max(0, \text{Area}(LV \setminus \text{Myocardium}));$$

– функція втрат суміжності, L_{adj} :

$$L_{\text{adj}} = \text{Distance}(RV, \text{Myocardium});$$

– функція втрат перекриття, L_{overlap} :

$$L_{\text{overlap}} = \text{Area}(\text{Overlap of non-adjacent structures}).$$

Крок 3.3. Загальна функція втрат для анатомічних обмежень

Загальна функція втрат визначено в такий спосіб:

$$L_{\text{anatomy}} = \lambda_{\text{enc}} L_{\text{enc}} + \lambda_{\text{adj}} L_{\text{adj}} + \lambda_{\text{overlap}} L_{\text{overlap}},$$

де λ_{enc} , λ_{adj} , $\lambda_{overlap}$ – вагові коефіцієнти.

У роботі було впроваджено додаткові задачі, що враховують експертні знання.

а) Визначення анатомічних орієнтирів: Прогнозування ключових точок анатомії.

б) Класифікація фаз серця: Визначення фаз серцевого циклу (систола, діастола).

Опис даних.

Для оцінювання запропонованого підходу було використано набір даних Automated Cardiac Diagnosis Challenge (ACDC) [1]. Нижче подамо коротку характеристику набору даних ACDC.

– Пацієнти: 100 осіб із різними кардіологічними станами (норма, інфаркт міокарда, дилатаційна кардіоміопатія, гіпертрофічна кардіоміопатія, аномалії правого шлуночка).

– Зображення: Послідовні зрізи МРТ, що охоплюють весь серцевий цикл.

– Анотації: Ручні сегментування LV, міокарда та RV разом з експертними анотаціями ROI та орієнтирів.

– Поділ даних: Навчальна вибірка (70 пацієнтів), валідація (10 пацієнтів), тестування (20 пацієнтів).

Процедура навчання моделі.

Модель глибокого навчання за архітектурою U-Net навчено через мінімізацію комбінованої функції втрат:

$$L_{total} = L_{seg} + \lambda_{anatomy} L_{anatomy} + \lambda_{aux} L_{aux},$$

де L_{seg} – функція втрат сегментування, L_{aux} – функція втрат для додаткових задач, $\lambda_{anatomy}$ і λ_{aux} – вагові коефіцієнти.

Вагові коефіцієнти λ ініціалізовано емпірично, з огляду на продуктивність за валідаційним набором. Безпосередньо для навчання моделі використано оптимізатор Adam із початковою швидкістю навчання (learning rate) 1×10^{-4} . Також до процесу навчання було застосовано раннє завершення навчання та метод регуляризації для запобігання перенавчанню.

Результати.

Результативність сегментування оцінено за коефіцієнтом Dice (DSC), індексом Жаккара (Jaccard), відстанню Гаусдорфа (HD) та середньою поверхневою відстанню (ASD).

В таблиці 1 подано результати обчислювальних експериментів. З таблиці 1 бачимо, що інтегрування експертних знань значно покращує продуктивність сегментування моделі U-Net. Використання механізмів уваги, керованих експертними анотаціями, дає змогу мережі фокусуватися на клінічно важливих областях, що підвищує якість подання ознак у цих регіонах. Анатомічні функції втрат забезпечують виконання реалістичних анатомічних співвідношень, що зменшує такі помилки, як некоректне маркування або перекриття структур.

Таблиця 1 – Порівняння результативності сегментації базової моделі U-Net та запропонованого підходу

| Ділянка серця | Модель | DSC, % ↑ | Jaccard, % ↑ | HD, мм ↓ | ASD, мм ↓ |
|---------------|---------------|-------------|-----------------|-------------|--------------|
| LV | Базовий U-Net | 93.0 ± 1.6 | 87.0 ± 2.0 | 8.0 ± 2.2 | 1.2 ± 0.4 |
| | Наш підхід | 95.5 ± 1.2 | 91.5 ± 1.5 | 5.5 ± 1.8 | 0.8 ± 0.3 |
| Міокард | Базовий U-Net | 85.5 ± 2.5 | 76.0 ± 3.0 | 9.8 ± 3.1 | 1.5 ± 0.5 |
| | Наш підхід | 89.0 ± 2.0 | 81.0 ± 2.5 | 6.5 ± 2.3 | 1.0 ± 0.4 |
| RV | Базовий U-Net | 90.0 ± 2.1 | 82.0 ± 2.5 | 8.5 ± 2.5 | 1.3 ± 0.4 |
| | Наш підхід | 93.0 ± 1.7 | 86.5 ± 2.0 | 6.0 ± 2.0 | 0.9 ± 0.3 |

Порівняння підходів за усіма метриками сегментування ілюстровано на рисунку 1.

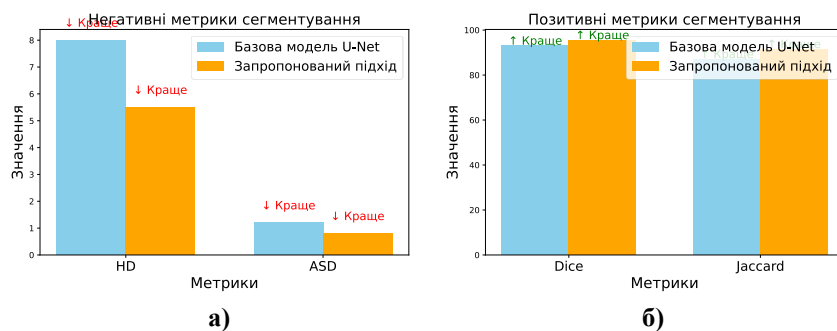


Рисунок 1 – Порівняння результатів сегментування моделей: запропонований підхід демонструє покращення за метриками Dice та Jaccard (позитивний тренд) і зниження помилок за метриками HD та ASD (негативний тренд) у порівнянні з базовою моделлю U-Net.

Рисунок 1 демонструє, що запропонований підхід перевершує базову модель U-Net за всіма ключовими метриками сегментації. Зокрема, вищі значення DSC та Jaccard свідчать про покращену якість сегментації, що краще відповідає реальним анатомічним структурам. Водночас, знижені значення HD та ASD вказують на менші геометричні похибки у сегментованих структурах, що є важливим для забезпечення анатомічної достовірності. Отже, інтеграція експертних знань, механізмів уваги та анатомічних обмежень у функції втрат забезпечує покращення результатів сегментації, що вказує на значну перспективу цього підходу для медичного діагностування за аналізом медичних зображень.

Нижче також подамо кілька обмежень запропонованого підходу, зокрема:

1. Залежність від експертних анотацій. Отримання анотацій може бути тривалим процесом і не завжди доступним у практичних умовах.
2. Додавання механізмів уваги та анатомічних втрат збільшує обчислювальні витрати.
3. Отримані кількісні результати є перспективними за набором даних ACDC, однак потрібна додаткова валідація за іншими наборами даних зображень MPT серця.

Висновки.

У цій роботі запропоновано вдосконалений підхід до інтегрування експертних знань у модель глибокого навчання типу U-Net для сегментування зображень МРТ серця. Використання механізмів уваги, що керовані експертними анотаціями, та впровадження анатомічних функцій втрат дало можливість покращити сегментування проти базової моделі U-Net. Отримані результати вказують на підвищення точності, анатомічної достовірності та клінічної релевантності сегментації. Подальша робота буде зосереджена на зменшенні залежності від експертних анотацій та розширенні застосування цього підходу до інших завдань сегментування в медичній візуалізації.

Список посилань.

1. *Deep learning techniques for automatic MRI cardiac multi-structures segmentation and diagnosis: Is the problem solved?* / O. Bernard et al. *IEEE Transactions on Medical Imaging*. 2018. Vol. 37, no. 11. P. 2514–2525. URL: <https://doi.org/10.1109/tmi.2018.2837502>
2. *Ronneberger O., Fischer P., Brox T. U-Net: convolutional networks for biomedical image segmentation. Lecture Notes in Computer Science. Cham, 2015. P. 234–241.* URL: https://doi.org/10.1007/978-3-319-24574-4_28
3. *Radiuk P. Applying 3D U-Net architecture to the task of multi-organ segmentation in computed tomography. Applied Computer Systems. 2020. Vol. 25, no. 1. P. 43–50.* URL: <https://doi.org/10.2478/acss-2020-0005>
4. *ACPL: Anti-curriculum pseudo-labelling for semi-supervised medical image classification* / F. Liu et al. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) : Proceedings, New Orleans, LA, USA, 18–24 June 2022. New York, NY, USA, 2022. P. 20697–20706.* URL: <https://doi.org/10.1109/cvpr52688.2022.02004>
5. *Chaban O. Integrating diagnostic models: A revolutionary approach in AI-driven healthcare. AI-Driven Transformation: Mapping the Course for Future Business Landscapes : Monograph / Gen. edit. O. Prokopenko, M. Jarvis, Tallinn: Teadmus OÜ, 2024, P. 204–216.* URL: <https://conference.euas.eu/2023/wp-content/uploads/2024/03/Monograph2023.pdf>

6. A survey on incorporating domain knowledge into deep learning for medical image analysis / X. Xie et al. *Medical Image Analysis*. 2021. Vol. 69. P. 101985. URL: <https://doi.org/10.1016/j.media.2021.101985>
7. Chaban O., Manziuk E. Enhancing medical NLI with integrated domain knowledge and sentiment analysis. *Information Control Systems & Technologies (ICST-2024) : CEUR-Workshop Proceedings, Odesa, Ukraine, 23–25 September 2024* / ed. by A. Pakštas et al. Vol. 3790. CEUR-WS.org, Aachen, 2024. P. 262–272. URL: <https://ceur-ws.org/Vol-3790/paper23.pdf>
8. Brauwers G., Frasincar F. A general survey on attention mechanisms in deep learning. *IEEE Transactions on Knowledge and Data Engineering*. 2021. Vol. 35, no. 4. P. 3279–3298. URL: <https://doi.org/10.1109/tkde.2021.3126456>
9. High-level prior-based loss functions for medical image segmentation: a survey / R. El Jurdi et al. *Computer Vision and Image Understanding*. 2021. Vol. 210. P. 103248. URL: <https://doi.org/10.1016/j.cviu.2021.103248>
10. Чабан О.Р., Манзюк Е.А. Метод інтегрування доменних знань у багатостратегічну класифікацію медичних зображень. *Вісник Хмельницького національного університету. Серія «Технічні науки»*. 2024. Т. 337, № 3(2). С. 231–236. URL: <https://doi.org/10.31891/2307-5732-2024-337-3-34>