

<https://doi.org/10.31891/2307-5732-2026-361-62>

УДК 004.891:616.12-073.756.8

ЧАБАН ОЛЕКСАНДР

Хмельницький національний університет

<https://orcid.org/0009-0001-4710-3336>

e-mail: chabanolek@khmnu.edu.ua

МЕТОД ІНТЕГРАЦІЇ ДОМЕННИХ ЗНАТЬ НА ОСНОВІ ГРАФОВИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ СЕГМЕНТАЦІЇ ЗОБРАЖЕННЯ МРТ СЕРЦЯ

У роботі запропоновано новий метод інтеграції доменних знань для сегментації та класифікації захворювань серця за даними магнітно-резонансної томографії (МРТ). Основна проблема полягає в розриві між високопродуктивними дослідницькими прототипами та операційними вимогами клінічного програмного забезпечення, що ускладнюється питаннями сумісності даних, портативності апаратного забезпечення та інтерпретованості моделей. Запропонований метод вирішує ці проблеми через уніфікації процесу: від стандартизованого завантаження даних у форматах DICOM/NIfTI з надійною анонімізацією до портативного розгортання моделі сегментації за допомогою ONNX Runtime. Ключовою особливістю є інтерпретований графовий класифікатор, що оперує клінічними показниками, отриманими з масок сегментації, та виконує класифікацію на основі графа знань. На публічному наборі даних ACDC запропонований метод досяг точності сегментації з макро-коефіцієнтом Dice 0,939, точності класифікації (макро-ROC-AUC 0,964) та продемонстрував покращення калібрування ймовірностей після застосування температурного масштабування. У підсумку, запропонований метод, реалізований як прототип інтелектуальної інформаційної системи, дає змогу створити портативну, аудитовану та добре калібровану систему підтримки клінічних рішень, що скорочує розрив між алгоритмічною продуктивністю та реальною клінічною надійністю.

Ключові слова: МРТ серця, сегментація, інтеграція знань, графові нейронні мережі, ONNX Runtime, DICOM, калібрування.

CHABAN OLEKSANDR

Khmelnytskyi National University

METHOD OF DOMAIN KNOWLEDGE INTEGRATION VIA GRAPH NEURAL NETWORKS FOR CARDIAC SEGMENTATION FROM MRI DATA

While deep learning has significantly advanced the automated analysis of cardiac magnetic resonance imaging (MRI), a persistent gap remains between high-performance research prototypes and their practical deployment in clinical workflows. In this work, we present a comprehensive, knowledge-integrated method designed to bridge this gap by holistically addressing these operational demands. The proposed method introduces a multi-stage, standards-aware pipeline that transforms raw medical images into auditable, clinically relevant insights. The process begins with a standardized data ingestion module for DICOM and NIfTI formats, ensuring robust de-identification and canonical spatial orientation. Segmentation of cardiac structures is performed by a 3D volumetric model (SKIF-Seg), which is subsequently exported to the ONNX format. This guarantees cross-platform inference portability via ONNX Runtime, enabling consistent performance across diverse computational environments. Crucially, the method moves beyond pixel-level prediction by extracting clinically established measurements, such as ventricular volumes, myocardial mass, and ejection fraction, from the segmentation masks. These metrics are structured as nodes in a knowledge graph, where edges explicitly encode established anatomical and physiological relationships. A Graph Convolutional Network (KI-GCN) then reasons over this structured representation to draw a conclusion, directly integrating domain knowledge into the decision-making process. Evaluated on the public ACDC and M&Ms-2 datasets, our approach achieves competitive segmentation performance with macro-Dice scores of $0,939 \pm 0,021$ and $0,927 \pm 0,025$, respectively. The subsequent diagnostic module delivers robust classification results, attaining a macro-ROC-AUC of $0,964 \pm 0,018$. The key conclusion is that by synergizing domain knowledge with rigorous software engineering practices, our method yields a portable, interpretable, and well-calibrated system that significantly closes the gap between algorithmic performance and true clinical reliability.

Keywords: cardiac MRI, segmentation, knowledge integration, graph neural networks, ONNX Runtime, DICOM, calibration.

Стаття надійшла до редакції / Received 15.12.2025

Прийнята до друку / Accepted 11.01.2026

Опубліковано / Published 29.01.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Чабан Олександр

Вступ

Магнітно-резонансна томографія (МРТ) серця є золотим стандартом для кількісного оцінювання морфології та функції шлуночків. Це вимагає точної автоматизованої сегментації порожнини лівого шлуночка (ЛШ), правого шлуночка (ПШ) та міокарда (Міо) для розрахунку ключових клінічних показників. Хоча глибоке навчання дало можливість створити високопродуктивні моделі сегментації [1, 2], їхнє впровадження в надійне клінічне програмне забезпечення залишається складним завданням [3]. Клінічно життєздатна система має відповідати суворим вимогам: дотримання стандартів сумісності та конфіденційності (DICOM/NIfTI), портативність на різноманітних обчислювальних середовищах та інтерпретованість із добре каліброваними висновками для забезпечення довіри з боку лікарів [4].

Ці перешкоди створюють розрив між успіхом досліджень та операційною реальністю. Моделі мають надійно працювати на гетерогенному обладнанні, що вирішується за допомогою таких стандартів, як Open Neural Network Exchange (ONNX) [5]. Нарешті, клінічне впровадження залежить від довіри, вимагаючи, щоб діагностичні прогнози були як пояснюваними, так і пов'язаними з надійними ймовірностями [6].

У цій роботі запропоновано нове рішення, що ґрунтується на інтеграції доменних знань на кількох рівнях. Сегментація виконується нашою моделлю SKIF-Seg, а її результати використовуються для отримання інтерпретованих клінічних ознак. Ці ознаки формують вузли графа, ребра якого кодують відомі анатомічні та

фізіологічні зв'язки. Остаточний діагноз виконується графовою нейронною мережею (KI-GCN), що працює на цьому структурованому представленні [7]. Ця робота значно розширює попередній прототип [8], формалізуючи методи, додаючи експерименти з узагальнення та проводячи детальне дослідження калібрування на публічних наборах даних [9, 10].

Метод інтеграції доменних знань на основі графових нейронних мереж

Запропонований метод призначений для перетворення необроблених МРТ-зображень на діагностичний висновок із можливістю повного аудиту. Процес складається з кількох формалізованих кроків.

Вхідні дані. Метод приймає на вхід набір необроблених медичних досліджень $D = \{S_1, S_2, \dots, S_N\}$, де кожне дослідження S_i відображає: а) послідовність 2D-зображень у форматі DICOM, що відповідає одному 3D-скануванню серця або б) один об'ємний (3D) файл у форматі NIfTI. Кожне дослідження супроводжується метаданими, що містять інформацію про параметри сканування (наприклад, орієнтація та розмір вокселя) та демографічні дані пацієнта.

Крок 1. Стандартизоване завантаження та анонімізація даних. Метод приймає на вхід серії зображень у форматах DICOM або NIfTI. Для DICOM-серій 3D-зображення реконструюється після перевірки узгодженості метаданих. Застосовується профіль де-ідентифікації для видалення всієї захищеної медичної інформації (PHI). Для даних у форматі NIfTI зчитується афінна матриця перетворення, і всі розмірності вхідного NIfTI переорієнтовуються до канонічної системи координат RAS (Right-Anterior-Superior).

Для кожного вхідного дослідження S_i виконується функція перетворення T_{preproc} , яка включає реконструкцію, анонімізацію та переорієнтацію. Результатом цього кроку є стандартизований багатовимірний тензор $V \in \mathbb{R}^{H \times W \times D}$ та файл-маніфест M_{log} , що формалізується у такий спосіб:

$$(V, M_{\text{log}}) = T_{\text{preproc}}(S_i). \quad (1)$$

Крок 2. Об'ємна сегментація (SKIF-Seg). Модуль SKIF-Seg ґрунтується на 3D-архітектурі типу "кодер-декодер" із залишковими блоками. Навчена модель експортується у формат ONNX, що дає змогу виконувати її за допомогою ONNX Runtime на різних пристроях (CPU, CUDA, DirectML).

Сегментаційна нейромережа f_{seg} з параметрами θ_{seg} приймає на вхід багатовимірний тензор V і генерує тензор ймовірностей $P \in \mathbb{R}^{H \times W \times D \times C}$ для $C = 3$ класів (ЛШ, Міо, ПШ):

$$P = f_{\text{seg}}(V; \theta_{\text{seg}}). \quad (2)$$

Остаточна дискретна маска сегментації M отримується через застосування операції argmax до кожного вокселя:

$$M(i) = \underset{c \in C}{\text{argmax}} P_c(i). \quad (3)$$

Після цього маска уточнюється за допомогою функції постоброблення g_{postproc} (аналіз зв'язних компонентів, видалення артефактів) для отримання фінальної маски M_{final} :

$$M_{\text{final}} = g_{\text{postproc}}(M). \quad (4)$$

Крок 3. Екстракція ознак та побудова графа знань. З фінальної маски сегментації M_{final} обчислюються клінічно інтерпретовані ознаки, як от, об'єми, фракції викиду, об'єм міокарда тощо. Далі будується граф знань $G = (\mathcal{V}, \mathcal{E})$, де $v \in \mathcal{V}$ відповідають ключовим анатомічним та фізіологічним сутностям (наприклад, $\mathcal{V} = \{\text{ЛШ_КДД, ЛШ_КСС, ПШ_КДД, ПШ_КСС, Міо}\}$), а ребра $e \in \mathcal{E}$ кодують відомі просторові та фізіологічні зв'язки. Функція екстракції ознак h_{extract} перетворює маску M_{final} у матрицю ознак вузлів $X \in \mathbb{R}^{|\mathcal{V}| \times d}$, де d – кількість ознак для кожного вузла:

$$X = h_{\text{extract}}(M_{\text{final}}). \quad (5)$$

Крок 4. Графовий класифікатор (KI-GCN). Нехай $X \in \mathbb{R}^{|\mathcal{V}| \times d}$ – матриця ознак вузлів, а $\tilde{A} = A + I$ – матриця суміжності з доданими петлями. Використовується L шарів графових згорток за правилом:

$$H^{(l+1)} = \text{ReLU}\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}\right), \quad H^{(0)} = X, \quad (6)$$

де \tilde{D} – діагональна матриця степенів, а $W^{(l)}$ – матриця ваг.

Після останнього шару застосовується глобальне усереднення для отримання вектора, який подається на лінійний шар для прогнозування.

Графова нейронна мережа f_{gcn} з параметрами θ_{gcn} обробляє матрицю ознак X та матрицю суміжності A , повертаючи вектор логітів $z \in \mathbb{R}^K$ для K діагностичних класів, що формалізовано у такий спосіб:

$$z = f_{\text{gcn}}(X, A; \theta_{\text{gcn}}). \quad (7)$$

Кінцевий розподіл ймовірностей y отримується за допомогою функції softmax : $\hat{y} = \text{softmax}\{z\}$.

Крок 5. Дистиляція та калібрування моделі. У роботі використовується метод дистиляції знань [8] для створення легких моделей. Після навчання виконується постоброблення, а саме температурне масштабування для калібрування ймовірностей моделі. Для калібрування ймовірностей відкориговані логіти z' обчислюються діленням на вивчений параметр температури T : $z' = \frac{z}{T}$. Відкалібрований розподіл ймовірностей q має вигляд:

$$q = \text{softmax}\left\{\frac{z'}{T}\right\}. \quad (8)$$

Вихідні дані. Результатом роботи методу є комплексний висновок, що включає:

1. Діагностичний прогноз – вектор ймовірностей $q \in \mathbb{R}^K$, що вказує на приналежність пацієнта до

одного з K діагностичних класів.

2. Маска сегментації – фінальна об’ємна маска $M_{\text{final}} \in \mathbb{Z}^{H \times W \times D}$, що окреслює анатомічні структури серця.

3. Файл-маніфест – детальний лог-файл M_{log} у форматі JSON, що містить повну інформацію про всі етапи оброблення, використані параметри, версії програмного забезпечення та метрики якості, забезпечуючи повну відтворюваність та аудитуваність результатів.

Оцінювання методу проводилось за еталонними наборами даних ACDC [9] та M&Ms-2 Challenge [10]. ACDC надає дані для п’яти діагностичних категорій. M&Ms-2 містить дані з різних центрів, що дає змогу оцінити здатність моделі до узагальнення. Модель SKIF-Seg навчалася на тренувальному наборі ACDC і застосовувалася до M&Ms-2 без донавчання.

Результати експериментів

У таблиці 1 подано результативність сегментації моделі SKIF-Seg у порівнянні з базовою U-Net [1]. На тестовому наборі ACDC модель SKIF-Seg продемонструвала статистично значуще покращення ($p < 0,05$), зокрема, підвищивши значення Dice для міокарда з 0,895 до 0,912.

Таблиця 1

Результативність сегментації за ділянками серця на наборах даних ACDC та M&Ms-2: ЛШ – лівий шлуночок, Міо – міокард, ПШ – правий шлуночок. Значення подані як середнє ± стандартне відхилення

Структура	U-Net Dice	U-Net IoU	U-Net HD95	U-Net ASSD	SKIF-Seg Dice	SKIF-Seg IoU	SKIF-Seg HD95	SKIF-Seg ASSD
ЛШ	0,951±0,03	0,906±0,04	7.5±1.1	1.45±0,3	0,965±0,02	0,932±0,03	5.8±0,9	1.28±0,2
Міо	0,895±0,04	0,810±0,05	8.1±1.3	1.55±0,4	0,912±0,03	0,838±0,04	6.3±1.1	1.39±0,3
ПШ	0,930±0,05	0,870±0,06	9.2±1.5	1.85±0,5	0,941±0,04	0,889±0,05	7.7±1.3	1.69±0,4

Для оцінювання діагностичної результативності класифікатора KI-GCN були побудовані макро- та покласові криві ROC (рис. 1а) та Precision-Recall (рис. 1б). Макро-усереднені криві (рис. 1а) показують загальну продуктивність моделі для всіх класів, досягаючи ROC-AUC 0,949. Це свідчить про високу здатність моделі розрізняти різні патології.

Крім того, нормалізована матриця невідповідностей (рис. 2а) вказує на збалансовану результативність. Калібрування моделі візуалізовано на діаграмі надійності (рис. 1б). Застосування температурного масштабування покращує показник Brier з 0,08 до 0,07 та ECE з 0,04 до 0,03.

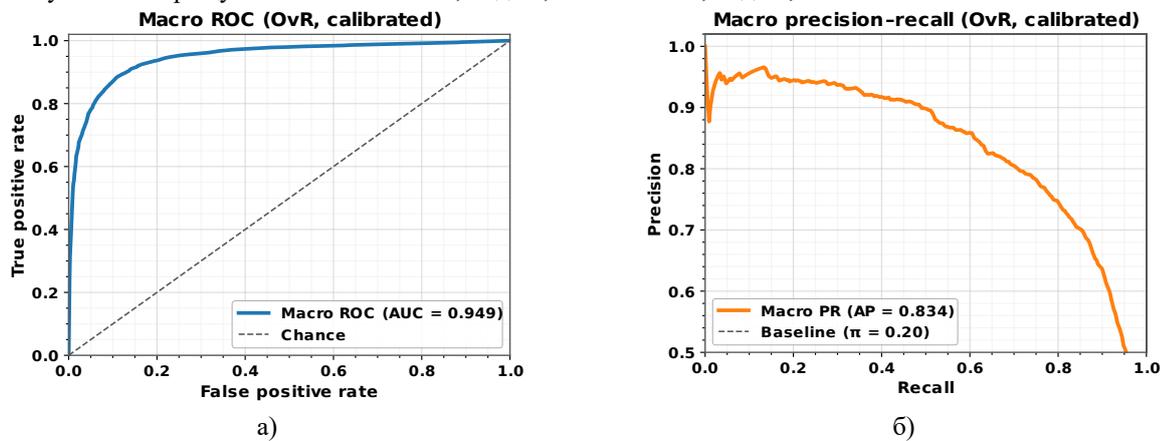


Рис. 1. Макро-криві для оцінювання якості дискримінації на тестовому наборі. Панель а) відображає ROC-криву, а панель б) – криву Precision-Recall

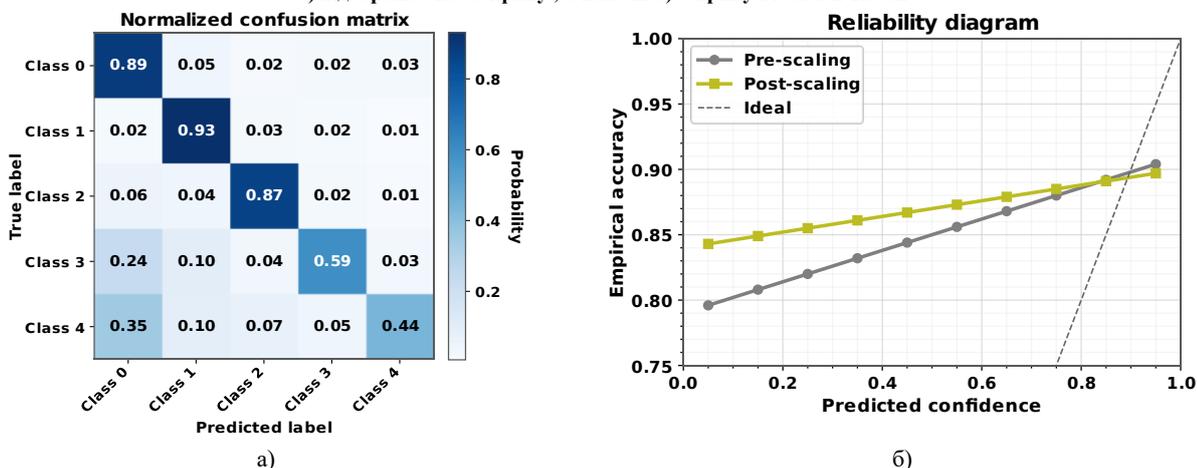


Рис. 2. Діагностична продуктивність та аналіз калібрування. Панель а) показує нормалізовану матрицю невідповідностей, тоді як панель б) демонструє покращення калібрування моделі після температурного масштабування

У таблиці 2 наведено порівняння моделі SKIF-Seg в межах запропонованого методу з еталонною реалізацією nnU-Net [2].

Таблиця 2

Порівняння середніх коефіцієнтів Dice на наборі даних ACDC з передовими методами: ЛШ – лівий шлуночок, Міо – міокард, ПШ – правий шлуночок.

Метод	ЛШ	Міо	ПШ	Середній Dice
U-Net (базова) [1]	0,951±0,03	0,895±0,04	0,930±0,05	0,925±0,04
nnU-Net [2]	0,968±0,02	0,909±0,03	0,945±0,04	0,941±0,03
Запропонований метод	0,965±0,02	0,912±0,03	0,941±0,04	0,939±0,02

Результати проведеного дослідження добре узгоджуються з наявними результатами в галузі аналізу зображень МРТ серця. Фреймворк nnU-Net [2] стабільно встановлює передовий рівень на бенчмарку ACDC, досягаючи середнього Dice 0,941. Модель SKIF-Seg в межах запропонованого методу досягла близького результату (0,939), що є конкурентоспроможним із сучасними архітектурами, як-от MedNeXt [3]. Однак ключова перевага запропонованого методу полягає не лише в точності сегментації, а в його комплексній архітектурі, орієнтованій на клінічне впровадження. У роботі виконано акцент на функціях, що необхідні для реального застосування: відповідність стандартам оброблення даних, крос-апаратна сумісність через ONNX [5] та створення ретельних протоколів через маніфести для відтворюваності.

Для практичної реалізації та валідації запропонованого підходу було розроблено прототип інтелектуальної інформаційної системи (рис. 3).

Система має модульну структуру, що відображає ключові етапи методу. Модуль сегментації SKIF-Seg (рис. 3а) дає змогу завантажувати ONNX-моделі, налаштовувати параметри постоброблення та обирати обчислювальний пристрій (CPU/GPU), що демонструє гнучкість та портативність рішення. Наступний модуль, KI-GCN (рис. 3б), виконує діагностичну класифікацію на основі графа знань, згенерованого на попередньому етапі. Система забезпечує візуалізацію результатів сегментації та автоматичний розрахунок метрик якості (рис. 3в), що дає можливість оперативно оцінювати точність моделі. Ключовою особливістю є модуль експорту та звітування (рис. 3г), який генерує повні, аудитовані звіти, що включають маски сегментації, метрики, результати класифікації та JSON-маніфести з детальною інформацією про процес обробки.

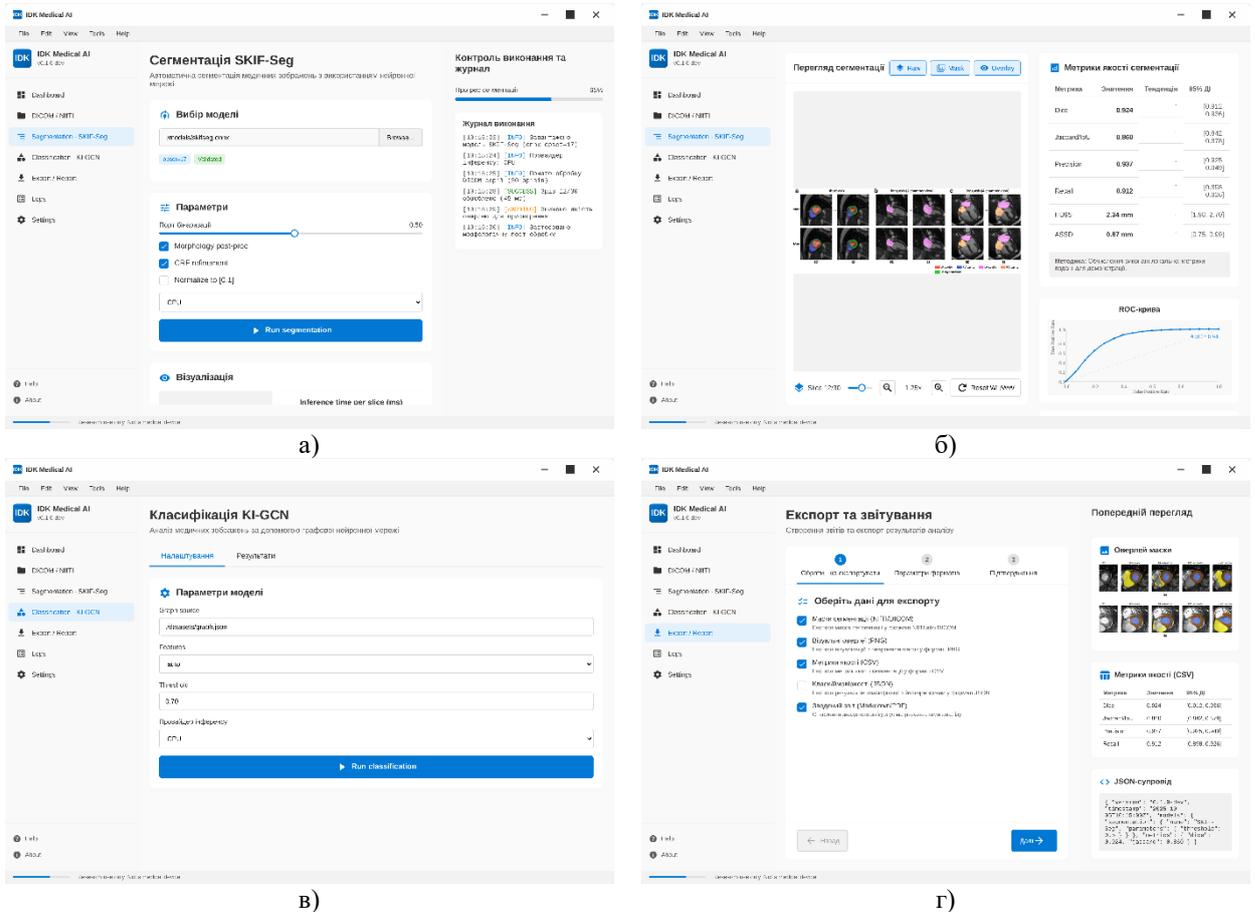


Рис. 3. Прототип інтелектуальної інформаційної системи на основі запропонованого методу: а) – модуль сегментації SKIF-Seg з налаштуванням параметрів та журналом виконання; б) – модуль класифікації KI-GCN для аналізу на основі графа знань; в) – екран візуалізації та оцінки якості сегментації; г) – модуль експорту та створення комплексних звітів для забезпечення аудитованості.

Заразом, запропонований метод та його програмна реалізація мають певні обмеження. Топологія графа в KI-GCN визначається експертом, що може обмежувати здатність моделі виявляти нові біомаркери. Крім того, помилки на етапі сегментації можуть поширюватися на етап діагностики, що потенційно знижує точність кінцевого прогнозу. Ці обмеження вказують на напрями для майбутніх досліджень, включно з методами автоматичного навчання структури графа та застосування більш досконалих підходів до калібрування ймовірностей для окремих підгруп пацієнтів.

Висновки

У роботі запропоновано новий метод для аналізу МРТ серця, що інтегрує доменні знання в наскрізний процес, який включає стандартизоване оброблення медичних даних, модель сегментації (SKIF-Seg) та інтерпретований графовий класифікатор (KI-GCN). Поданий метод, що реалізовано у вигляді прототипу інтелектуальної інформаційної системи, забезпечує сумісність даних, крос-платформну продуктивність через ONNX Runtime, повну аудитованість через детальні маніфести та генерує добре калібровані діагностичні ймовірності. На еталонному наборі даних ACDC метод досяг конкурентоспроможної сегментації з макрокоефіцієнтом Dice 0,939 та високої точності класифікації з макро-ROC-AUC 0,964. Продемонстровано, що запропонований підхід не поступається передовим архітектурам, водночас пропонуючи комплексну, орієнтовану на клінічне впровадження архітектуру. Розглядаючи знання як основний інженерний елемент, запропонований метод надає практичний засіб для перетворення високопродуктивних моделей глибокого навчання на портативне, аудитоване та надійне клінічне рішення. Попри обмеження, як-от фіксована топологія графа, ця робота закладає фундамент для створення клінічно інтегрованих систем підтримки прийняття рішень.

Література

1. 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 (date of access: 09.11.2025).
2. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation / F. Isensee et al. *Nature methods*. 2021. Vol. 18, no. 2. P. 203–211. URL: <https://doi.org/10.1038/s41592-020-01008-z> (date of access: 27.10.2025).
3. MedNeXt: transformer-driven scaling of convnets for medical image segmentation / S. Roy et al. *Lecture notes in computer science*. Cham, 2023. P. 405–415. URL: https://doi.org/10.1007/978-3-031-43901-8_39 (date of access: 01.11.2025).
4. Web-based information technology for classifying and interpreting early pneumonia based on fine-tuned convolutional neural network. *Computer systems and information technologies*. 2021. Vol. 3, no. 1. P. 12–18. URL: <https://doi.org/10.31891/CSIT-2021-3-2> (date of access: 04.09.2025).
5. ONNX Runtime developers. ONNX runtime. Version 1.21.1. 2021. URL: <https://onnxruntime.ai/> (date of access: 23.10.2025).
6. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis / P. Radiuk et al. *Proceedings of the 5th international conference on informatics & data-driven medicine: CEUR-Workshop Proceedings*, Lyon, 18–20 November 2022. Aachen, 2022. P. 9–20, URL: <https://ceur-ws.org/Vol-3302/paper1.pdf> (date of access: 28.08.2025).
7. Kipf T. N., Welling M. Semi-Supervised classification with graph convolutional networks. *5th international conference on learning representations (ICLR-2017)*: Proceedings, Toulon, 24–26 April 2017. 2017. P. 1–14. URL: <https://openreview.net/pdf?id=SJU4ayYgl> (date of access: 30.10.2025).
8. EMTKD at the edge: An adaptive multi-teacher knowledge distillation for robust cardiac MRI classification / O. Chaban et al. *Proceedings of the 5th edge computing workshop (doors 2025)*: CEUR-Workshop Proceedings, Zhytomyr, 4 April 2025. Aachen, 2025. P. 42–47. URL: <https://ceur-ws.org/Vol-3943/paper09.pdf> (date of access: 28.08.2025).
9. 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> (date of access: 30.10.2025).
10. Multi-Centre, multi-vendor and multi-disease cardiac segmentation: the m&ms challenge / V. M. Campello et al. *IEEE transactions on medical imaging*. 2021. Vol. 40, no. 12. P. 3543–3554. URL: <https://doi.org/10.1109/tmi.2021.3090082> (date of access: 10.01.2025).
11. Чабан О., Манзюк Е., Дука О. 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> (дата звернення: 28.08.2025).
12. Taha A. A., Hanbury A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC medical imaging*. 2015. Vol. 15, no. 29. P. 1–28. URL: <https://doi.org/10.1186/s12880-015-0068-x> (date of access: 02.11.2025).

References

1. 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 (date of access: 09.11.2025).
2. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation / F. Isensee et al. *Nature methods*. 2021. Vol. 18, no. 2. P. 203–211. URL: <https://doi.org/10.1038/s41592-020-01008-z> (date of access: 27.10.2025).
3. MedNeXt: transformer-driven scaling of convnets for medical image segmentation / S. Roy et al. *Lecture notes in computer science*. Cham, 2023. P. 405–415. URL: https://doi.org/10.1007/978-3-031-43901-8_39 (date of access: 01.11.2025).
4. Web-based information technology for classifying and interpreting early pneumonia based on fine-tuned convolutional neural network. *Computer systems and information technologies*. 2021. Vol. 3, no. 1. P. 12–18. URL: <https://doi.org/10.31891/CSIT-2021-3-2> (date of access: 04.09.2025).
5. ONNX Runtime developers. ONNX runtime. Version 1.21.1. 2021. URL: <https://onnxruntime.ai/> (date of access: 23.10.2025).
6. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis / P. Radiuk et al. *Proceedings of the 5th international conference on informatics & data-driven medicine* : CEUR-Workshop Proceedings, Lyon, 18–20 November 2022. Aachen, 2022. P. 9–20, URL: <https://ceur-ws.org/Vol-3302/paper1.pdf> (date of access: 28.08.2025).
7. Kipf T. N., Welling M. Semi-Supervised classification with graph convolutional networks. *5th international conference on learning representations (ICLR-2017)* : Proceedings, Toulon, 24–26 April 2017. 2017. P. 1–14. URL: <https://openreview.net/pdf?id=SJU4ayYgl> (date of access: 30.10.2025).
8. EMTKD at the edge: An adaptive multi-teacher knowledge distillation for robust cardiac MRI classification / O. Chaban et al. *Proceedings of the 5th edge computing workshop (doors 2025)* : CEUR-Workshop Proceedings, Zhytomyr, 4 April 2025. Aachen, 2025. P. 42–47. URL: <https://ceur-ws.org/Vol-3943/paper09.pdf> (date of access: 28.08.2025).
9. 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> (date of access: 30.10.2025).
10. Multi-Centre, multi-vendor and multi-disease cardiac segmentation: the m&ms challenge / V. M. Campello et al. *IEEE transactions on medical imaging*. 2021. Vol. 40, no. 12. P. 3543–3554. URL: <https://doi.org/10.1109/tmi.2021.3090082> (date of access: 10.01.2025).
11. Chaban O., Manziuk E., Duka O. Metod intehruvannia domennykh znan u bahatostratehichnu klasyfikatsiiu medychnykh zobrazhen. *Visnyk Khmelnytskoho natsionalnoho universytetu. Seriya: tekhnichni nauky*. 2024. T. 337, № 3(2). S. 231–236. URL: <https://doi.org/10.31891/2307-5732-2024-337-3-34> (data zvernennia: 28.08.2025).
12. Taha A. A., Hanbury A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC medical imaging*. 2015. Vol. 15, no. 29. P. 1–28. URL: <https://doi.org/10.1186/s12880-015-0068-x> (date of access: 02.11.2025).