

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
МІНІСТЕРСТВА ОСВІТИ І НАУКИ УКРАЇНИ

Кваліфікаційна наукова праця
на правах рукопису

ЧАБАН ОЛЕКСАНДР РОМАНОВИЧ

УДК 004.85:004.9:616-07

ДИСЕРТАЦІЯ

**МЕТОДИ ТА ЗАСОБИ ІНТЕГРАЦІЇ ЗНАНЬ В МОДЕЛІ ШТУЧНОГО
ІНТЕЛЕКТУ МЕДИЧНИХ ДІАГНОСТИЧНИХ КОМПЛЕКСІВ**

122 Комп'ютерні науки
(шифр і назва спеціальності)

12 Інформаційні технології
(галузь знань)

Подається на здобуття наукового ступеня доктора філософії

Дисертація містить результати власних досліджень. Подані до захисту наукові положення є власним напрацюванням. Всі використані ідеї, наукові результати, цитати супроводжуються належними посиланнями на їх авторів та джерела опублікування. Всі частини тексту дисертації, під час написання яких використовувались технології штучного інтелекту, перевірені та відредаговані особисто.


(підпис)

Чабан Олександр Романович

Наукові керівники:

Манзюк Едуард Андрійович, доктор технічних наук, професор

Кльоц Юрій Павлович, кандидат технічних наук, доцент

АНОТАЦІЯ

Чабан О. Р. Методи та засоби інтеграції знань в моделі штучного інтелекту медичних діагностичних комплексів. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії з галузі знань 12 Інформаційні технології за спеціальністю 122 Комп'ютерні науки. – Хмельницький національний університет, Хмельницький, 2026.

Сучасний етап розвитку медичної науки та клінічної практики характеризується експоненціальним зростанням обсягів діагностичних даних, що вимагає впровадження новітніх інформаційних технологій, зокрема систем штучного інтелекту (ШІ), для їхнього опрацювання, аналізу та інтерпретації. Фундаментальний прогрес у галузі комп'ютерного виявлення та діагностування значною мірою зумовлений розвитком методів глибокого навчання, які продемонстрували здатність апроксимувати складні нелінійні залежності в багатовимірних просторах ознак.

Проте класичні статистичні методи, що ґрунтуються виключно на аналізі масивів даних, досягли межі своєї ефективності. Це зумовлено характерним для медичної галузі дефіцитом анотованих наборів даних, високою варіативністю діагностичного обладнання (явище «доменного зсуву») та наявністю «семантичного розриву» між ознаками низького піксельного рівня та високорівневими клінічними поняттями. Ігнорування верифікованих медичних знань, як от анатомічних, фізіологічних, патологічних та процедурних, призводить до створення моделей, які є вразливими до стохастичних збурень, погано інтерпретованими (ефект «чорної скриньки») та схильними до критичних топологічних і логічних помилок. Це створює системні бар'єри для безпечного клінічного впровадження ШІ. З огляду на це, актуальною науково-прикладною задачею є підвищення точності та клінічної обґрунтованості процесу прийняття рішень через перехід до гібридних архітектур, що інтегрують формалізовані

експертні знання в нейромережеві моделі на етапах сегментації, класифікації та оброблення природної мови.

Об'єктом дослідження є процеси інтеграції знань та опрацювання даних у системах штучного інтелекту медичних діагностичних комплексів.

Предметом дослідження є методи та засоби інтеграції експертних знань у моделі глибокого навчання для задач сегментації, класифікації медичних зображень та аналізу текстових клінічних даних.

Метою дослідження є підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах через створення методів та засобів інтеграції експертних знань у моделі штучного інтелекту.

Для досягнення поставленої мети сформульовано та розв'язано такі завдання.

1. Провести аналіз сучасного стану методів глибокого навчання та підходів до формалізації медичних знань, виявити наявні обмеження статистичних підходів та визначити перспективи створення гібридних архітектур.

2. Розробити метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня для забезпечення точності процесу діагностування в умовах зсуву домену та обмеженої розмітки даних.

3. Розробити метод встановлення смислових зв'язків у медичних текстах через інтеграцію онтологічних знань та аналізу тональності в архітектуру нейронної мережі для підвищення точності інтерпретації клінічних записів.

4. Розробити метод сегментації зображень магнітно-резонансної томографії серця, що ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги та спеціалізованої функції втрат із топологічними обмеженнями для забезпечення анатомічної коректності результатів.

5. Розробити метод ідентифікації патологій із використанням графової згорткової мережі, який інтегрує реляційні діагностичні знання та дає змогу моделювати взаємозв'язки між анатомічними структурами.

6. Спроекувати архітектуру інтелектуальної інформаційної системи інтеграції знань, яка забезпечує гнучке оброблення гетерогенних медичних даних

та підтримку модульної взаємодії між компонентами сегментації, класифікації та аналізу текстів.

7. Виконати програмну реалізацію інтелектуальної інформаційної системи інтеграції знань на основі спроектованої архітектури, здійснити постановку експерименту та провести комплексні експериментальні дослідження для підтвердження підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах на еталонних медичних наборах даних.

Наукова новизна отриманих результатів полягає в такому:

1) удосконалено метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня, який відрізняється від аналогів використанням динамічного ансамблю моделей-вчителів зі спеціалізованою моделлю для змагальної адаптації домену та механізмом селективної фільтрації, що дає змогу накопичувати досвід із різних клінічних доменів та передавати його компактній моделі-учню, підвищуючи в такий спосіб точність процесу прийняття рішень за варіативності вхідних даних;

2) удосконалено метод встановлення смислових зв'язків у медичних текстах, який, на відміну від наявних, поєднує інтеграцію онтологічних знань та явне кодування інформації про тональність і заперечення, що підвищує точність інтерпретації клінічних записів та забезпечує логічну узгодженість висновків;

3) розроблено новий метод сегментації зображень магнітно-резонансної томографії серця, який ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги для фокусування на складних ділянках та спеціалізованої функції втрат із топологічними обмеженнями на основі знакової відстані, який, на відміну від наявних підходів, дає змогу явно кодувати вкладеність та суміжність анатомічних структур, що забезпечує підвищення точності визначення меж органів та усунення топологічних артефактів;

4) розроблено новий метод ідентифікації патологій серця за зображенням магнітно-резонансної томографії із використанням графової згорткової мережі, орієнтованої на знання, який, на відміну від відомих рішень, реалізує парадигму реляційного міркування на графах, де вузли об'єднують гібридні візуальні та морфологічні ознаки, а матриця суміжності формується як суперпозиція

просторових зв'язків та клінічних кореляцій із медичних настанов, що дає можливість підвищити точність класифікації діагнозів та забезпечити інтерпретованість прийнятих рішень.

На основі розроблених математичних моделей спроектовано та реалізовано програмний комплекс «IDK Medical AI», побудований за принципами модульної мікросервісної архітектури. Результативність методів підтверджено на еталонних медичних наборах даних. Так, впровадження удосконаленого методу адаптивної дистиляції знань від моделей-вчителів до моделі-учня забезпечило підвищення метрики точності класифікації (AUC-ROC) на цільовому домені до 81,45 % за наявності лише 500 розмічених зразків (приріст на 8,8 % порівняно з базовими методами адаптації). Удосконалений метод встановлення смислових зв'язків у медичних текстах досяг точності 81,14 % (F1 79,85 %), суттєво покращивши виявлення медичних заперечень. Застосування нового методу сегментації до аналізу зображень магнітно-резонансної томографії серця дало змогу знизити метрику просторової похибки HD95 для міокарда з 9,8 мм до 6,5 мм, збільшивши коефіцієнт Дайса для лівого шлуночка до 95,5 %, усунувши при цьому критичні топологічні артефакти. Розроблений новий метод ідентифікації патологій серця за зображенням магнітно-резонансної томографії із використанням графової згорткової мережі забезпечив точність класифікації 5 патологічних станів серця на рівні 94,0 %, перевершивши базові нейромережеві моделі на 9,0 %, зберігаючи при цьому стійкість до локальних шумів сегментації.

Одержані теоретичні та практичні результати впроваджено у: навчальний процес Львівського торговельно-економічного університету (акт від 28.10.2025) для викладання дисциплін з інтелектуального аналізу даних; діяльність Хмельницької інфекційної лікарні (акт від 12.11.2025) для автоматизованого аналізу анонімізованих ультразвукових досліджень серця; виробничий процес ТОВ «КЦ НЕЙРОН» (акт від 22.10.2025) під час розроблення систем підтримки прийняття рішень; а також використано під час виконання держбюджетної науково-дослідної теми Хмельницького національного університету (№ держреєстрації 0124U004665).

У вступі обґрунтовано актуальність дослідження, визначено об'єкт, предмет, мету й завдання роботи. Висвітлено наукову новизну, практичне значення отриманих результатів та наведено інформацію щодо їхньої апробації.

У першому розділі здійснено ґрунтовний аналіз сучасного стану технологій штучного інтелекту в радіології та NLP. Доведено, що методи глибокого навчання, орієнтовані суто на статистичний розподіл пікселів чи токенів, вичерпали свій потенціал в умовах дефіциту даних. Систематизовано підходи до формалізації медичних знань (анатомічних, процедурних, онтологічних) та виявлено фрагментарність сучасних рішень. Сформульовано вимоги до перспективних гібридних архітектур, що мають гарантувати топологічну коректність, стійкість до доменних зсувів та здатність до реляційного міркування.

У другому розділі розкрито математичне та алгоритмічне забезпечення методів передачі експертних знань. Деталізовано метод адаптивної дистиляції знань від моделей-вчителів, формалізовано задачу доменної адаптації та описано роботу агрегаційної мережі багат шарового перцептрона. Також наведено структуру методу OPNI для аналізу медичних текстів. Описано процедуру генерації композитних векторних представлень (BioELMo, MultE, вектор сентименту) та розрахунку матриці перехресної уваги у двонаправленій LSTM-мережі для розв'язання задач логічного виведення.

У третьому розділі наведено теоретичні засади інтеграції топологічних та реляційних знань у стохастичні моделі. Запропоновано метод сегментації SKIF-Seg, формалізовано складену цільову функцію втрат, що включає базові та топологічні компоненти на основі знакових відстаней для контролю вкладеності та суміжності. Описано метод ідентифікації патологій KI-GCN, деталізовано процес формування зваженої матриці суміжності графа пацієнта та механізм глобальної субдискретизації уваги для забезпечення прозорості діагностичного висновку.

У четвертому розділі подано концептуальну архітектуру та технічні деталі реалізації програмного комплексу «IDK Medical AI». Наведено методологію проведення обчислювальних експериментів. Проаналізовано кількісні метрики (AUC-ROC, F_1 , DSC, HD95) на еталонних медичних наборах даних MIMIC-CXR,

MedNLI, ACDC та M&Ms-2. Проведено абляційне дослідження, яке статистично підтвердило синергетичний внесок кожного компонента розроблених методів у загальне підвищення якості моделей. Оцінено обчислювальну складність інференсу та доведено практичну придатність системи для використання в клінічних умовах.

У висновках наведено узагальнені підсумки дисертаційної роботи, що підтверджують виконання всіх поставлених завдань та досягнення мети дослідження щодо підвищення точності діагностичних комплексів унаслідок інтеграції експертних знань.

Дисертаційна робота складається з анотації, змісту, переліку умовних скорочень, вступу, чотирьох розділів, висновків, списку використаних джерел та п'яти додатків. Повний обсяг роботи становить 182 сторінки друкованого тексту, з них основний текст подано на 130 сторінках. Дисертація містить 54 рисунки та 27 таблиць. Список використаних джерел налічує 142 найменування на 20 сторінках. За темою дисертації опубліковано 12 наукових праць, поміж яких 1 стаття у виданні, що індексується наукометричною базою Scopus, 3 статті у фахових виданнях України категорії «Б», 6 публікацій у матеріалах конференцій, 1 розділ у колективній монографії та 1 свідоцтво про реєстрацію авторського права на комп'ютерну програму.

Ключові слова: штучний інтелект, глибоке навчання, інтеграція знань, дистиляція знань, комп'ютерний зір, сегментація зображень, обробка природної мови, графові згорткові мережі.

ANNOTATION

The current stage of development of medical science and clinical practice is characterised by exponential growth in the volume of diagnostic data, which requires the introduction of modern information technologies, particularly artificial intelligence (AI) systems, for their processing, analysis, and interpretation. Fundamental progress in computer-aided detection and diagnosis is mainly due to the development of deep

learning methods that have demonstrated the ability to approximate complex nonlinear relationships in multidimensional feature spaces.

However, classical statistical methods based solely on data array analysis have reached the limits of their effectiveness. This is due to the deficit of annotated datasets characteristic of the medical field, the high variability of diagnostic equipment (the phenomenon of “domain shift”), and the presence of a “semantic gap” between low-level pixel features and high-level clinical concepts. Ignoring verified medical knowledge, such as anatomical, physiological, pathological, and procedural knowledge, leads to the creation of models that are vulnerable to stochastic perturbations, poorly interpretable (the “black box” effect), and prone to critical topological and logical errors. This creates systemic barriers to the safe clinical implementation of AI. Given this, an urgent scientific and applied task is to improve the accuracy and clinical validity of the decision-making process through the transition to hybrid architectures that integrate formalised expert knowledge into neural network models at the stages of segmentation, classification, and natural language processing.

The object of the research is the processes of knowledge integration and data processing in artificial intelligence systems of medical diagnostic complexes.

The subject of the research is the methods and tools for integrating expert knowledge into deep learning models for the tasks of medical image segmentation, classification, and clinical text data analysis.

The goal of the research is to increase the accuracy and clinical validity of the decision-making process in medical diagnostic complexes by creating methods and tools for integrating expert knowledge into artificial intelligence models.

To achieve the set goal, the following tasks were formulated and solved:

1. Conducted an analysis of the current state of deep learning methods and approaches to formalising medical knowledge, identified the existing limitations of statistical approaches, and determined the prospects for creating hybrid architectures.

2. Developed a method of adaptive knowledge distillation from teacher models to a student model to ensure the accuracy of the diagnostic process under conditions of domain shift and limited data annotation.

3. Developed a method for establishing semantic relationships in medical texts through the integration of ontological knowledge and sentiment analysis into the neural network architecture to improve the accuracy of interpreting clinical notes.

4. Developed a method for segmenting cardiac MRIs, based on the synergistic combination of an expert-guided attention mechanism and a specialised loss function with topological constraints to ensure the anatomical correctness of the results.

5. Developed a method for identifying pathologies using a knowledge-informed graph convolutional network, which integrates relational diagnostic knowledge and enables the modelling of interconnections between anatomical structures.

6. Designed the architecture of an intelligent information system for knowledge integration, which ensures flexible processing of heterogeneous medical data and supports modular interaction between segmentation, classification, and text analysis components.

7. Implemented the software of the intelligent information system for knowledge integration based on the designed architecture, set up the experiment, and conducted comprehensive experimental studies to confirm the increased accuracy and clinical validity of the decision-making process.

The scientific novelty of the obtained results is as follows:

1) improved the method of adaptive knowledge distillation (EMTKD) from teacher models to a student model. Unlike existing analogues, the method uses a dynamic ensemble of teacher models combined with a specialised model for adversarial domain adaptation and a selective filtering mechanism based on an indicator function. This allows optimising the transfer of generalised continuous probability distributions to a compact student model, isolating the errors of individual teachers and increasing identification accuracy under equipment heterogeneity;

2) improved the method of establishing semantic relationships in medical texts (OPNI). Unlike classical contextual models, the proposed approach implements parallel processing channels: generating lexical context vectors (BioELMo), ontological knowledge vectors from UMLS graphs (MultE), and specialised binary vectors of modality and negation (NegEx). The synthesis of these features through an alignment

mechanism (Attention) ensures the recognition of false logical contradictions and improves the accuracy of clinical logical inference;

3) developed a new method for segmenting cardiac MRI images (SKIF-Seg). The proposed method is based on the synergistic interaction of an expert-guided attention mechanism (EGA) for local focusing and a developed loss function with topological constraints (TAAC). Unlike standard pixel-wise accuracy metrics, TAAC uses signed distance functions (SDF) to mathematically encode the requirements for the containment and adjacency of anatomical structures, which eliminates the occurrence of topological artefacts (contour breaks, isolated objects);

4) developed a new method for identifying cardiac pathologies using MRI images (KI-GCN). The method implements the paradigm of relational reasoning through the use of graph convolutional networks. The novelty lies in the formation of hybrid node vectors (morphological and deep texture features) and the construction of an adjacency matrix as a superposition of spatial proximity and clinical correlations extracted from medical guidelines. The application of a global attention pooling (GAP) mechanism ensures transparent interpretability of each organ's contribution to the final diagnosis.

The practical significance of the obtained results. Based on the developed mathematical models, the software complex “IDK Medical AI” was designed and implemented, built on the principles of modular microservice architecture. The effectiveness of the methods was confirmed on benchmark medical datasets MIMIC-CXR, ACDC, M&Ms-2, and MedNLI. Thus, the implementation of the EMTKD method ensured an increase in the AUC-ROC metric on the target domain to 81.45% with only 500 labelled samples (an 8.8% increase compared to baseline adaptation methods). The OPNI text analysis method achieved an accuracy of 81.14% (F_1 79.85%), significantly improving the detection of medical negations. The application of the SKIF-Seg segmentation method allowed for reducing the HD95 spatial error metric for the myocardium from 9.8 mm to 6.5 mm, increasing the Dice Similarity Coefficient (DSC) for the left ventricle to 95.5%. The KI-GCN method ensured a classification accuracy of 5 cardiac pathological states at the level of 94.0%, outperforming baseline 3D-CNNs by 9.0%, while maintaining robustness to local segmentation noise.

The obtained theoretical and practical results have been implemented in: the educational process of the Lviv University of Trade and Economics (implementation act dated 28.10.2025) for teaching data mining disciplines; the activities of the Khmelnytskyi Infectious Diseases Hospital (implementation act dated 12.11.2025) for the automated analysis of anonymized ultrasound examinations of the heart; the production process of LLC “KC NEURON” (implementation act dated 22.10.2025) during the development of decision support systems; and were also used during the execution of the state budget scientific research theme of the Khmelnytskyi National University (state registration No. 0124U004665).

In the introduction, the relevance of the study is substantiated, and the object, subject, goal, and tasks of the work are defined. The scientific novelty and practical significance of the obtained results are highlighted, and information regarding their approbation is provided.

The first chapter provides a thorough analysis of the current state of artificial intelligence technologies in radiology and NLP. It is proven that deep learning methods, purely focused on the statistical distribution of pixels or tokens, have exhausted their potential under conditions of data scarcity. Approaches to the formalisation of medical knowledge (anatomical, procedural, and ontological) are systematised, and the fragmentation of modern solutions is identified. Requirements for prospective hybrid architectures, which must guarantee topological correctness, robustness to domain shifts, and the ability for relational reasoning, are formulated.

The second chapter reveals the mathematical and algorithmic provision of methods for transferring expert knowledge. The method of adaptive knowledge distillation (EMTKD) is detailed, the domain-adaptation problem is formalised, and the operation of the multilayer perceptron aggregation network is described. The structure of the OPNI method for analysing medical texts is also presented. The procedure for generating composite vector representations (BioELMo, MultE, sentiment vector) and calculating the cross-attention matrix in a bidirectional LSTM network to solve logic inference tasks is described.

The third chapter presents the theoretical foundations for integrating topological and relational knowledge into stochastic models. The SKIF-Seg segmentation method is proposed, and a composite objective loss function is formalised that includes baseline and topological components based on signed distances to control containment and adjacency. The KI-GCN pathology identification method is described, detailing the process of forming a weighted adjacency matrix of the patient's graph and the mechanism of global attention pooling to ensure the transparency of the diagnostic conclusion.

The fourth chapter presents the conceptual architecture and technical details of the implementation of the “IDK Medical AI” software complex. The methodology for conducting computational experiments is provided. Quantitative metrics (AUC-ROC, F_1 , DSC, HD95) on the benchmark medical datasets MIMIC-CXR, MedNLI, ACDC, and M&Ms-2 are analysed. An ablation study was conducted, which statistically confirmed the synergistic contribution of each component of the developed methods to the overall improvement of model quality. The computational complexity of the inference is estimated, and the practical suitability of the system for clinical use is demonstrated.

The Conclusions summarise the results of the thesis work, confirming the fulfilment of all assigned tasks and the achievement of the research goal of increasing the accuracy of diagnostic complexes through the integration of expert knowledge.

The thesis consists of an abstract, a table of contents, a list of abbreviations, an introduction, four chapters, a conclusion, a list of references, and five appendices. The total volume of the work is 182 pages of printed text, of which the main text is presented on 130 pages. The thesis contains 54 figures and 27 tables. The list of references includes 142 entries on 20 pages. According to the topic of the thesis, 12 scientific papers have been published, including 1 article in a periodical indexed in the Scopus scientometric database, 3 articles in professional scientific journals of Ukraine (Category “B”), 6 publications in conference proceedings, 1 chapter in a collective monograph, and 1 certificate of copyright registration for a computer program.

Keywords: artificial intelligence, deep learning, knowledge integration, knowledge distillation, computer vision, image segmentation, natural language processing, graph convolutional networks.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у періодичних виданнях, включених до категорії «А» Переліку наукових фахових видань України, або у закордонних виданнях, проіндексованих у базах даних Web of Science Core Collection та/або Scopus

1. Chaban O., Manziuk E., Radiuk P. Method of adaptive knowledge distillation from multi-teacher to student deep learning models. *Journal of edge computing*. 2025. Vol. 4, no. 2. P. 159–178. URL: <https://doi.org/10.55056/jec.978> (індексована в наукометричній базі Scopus)

Статті у наукових виданнях, включених до Переліку наукових фахових видань України:

2. Чабан О. Р. Метод інтеграції доменних знань на основі графових нейронних мереж для сегментації зображення МРТ серця. *Вісник Хмельницького національного університету. Серія: технічні науки*. 2025. Т. 361, № 1. С. 452–457. URL: <https://doi.org/10.31891/2307-5732-2026-361-62>

3. Чабан О. Р. Метод поєднання контекстних векторних представлень слів із векторним поданням медичного домену. *Вимірювальна та обчислювальна техніка в технологічних процесах*. 2025. Вип. 82, № 2. С. 297–301. URL: <https://doi.org/10.31891/2219-9365-2025-82-42>

4. 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>

Праці, які засвідчують апробацію матеріалів дисертації

5. Intelligent information system for knowledge integration into artificial intelligence models / O. Chaban et al. *Proceedings of the 2nd International Workshop on Advanced Applied Information Technologies: AI & DSS: CEUR-Workshop Proceedings*,

Khmelnitskyi, Ukraine, Zilina, Slovakia, 5 December 2025. Aachen, 2026. P. 145–161.

URL: <https://ceur-ws.org/Vol-4163/paper13.pdf>

6. Knowledge-integrated graph networks for interpretable cardiac MRI analysis / O. Chaban et al. *Proceedings of the 8th international conference on informatics & data-driven medicine* : CEUR-Workshop Proceedings, Lviv, Ukraine, 19–20 November 2025. Aachen, 2025. P. 1–15.

7. 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, Ukraine, 4 April 2025. Aachen, 2025. P. 42–57. URL: <https://ceur-ws.org/Vol-3943/paper09.pdf> (індексована в наукометричній базі Scopus)

8. Чабан О. Р., Манзюк Е. А. Підхід до інтегрування експертних знань в модель U-Net для сегментування зображень МРТ серця. *Нейромережні технології та їх застосування НМТЗ-2024* : матеріали XXII Міжнар. наук. конф., м. Краматорськ-Вінниця-Тернопіль, 11–12 груд. 2024 р. Краматорськ, 2024. С. 145–149. URL: <https://elar.khmnmu.edu.ua/handle/123456789/17766>

9. Чабан О. Р., Манзюк Е. А. Метод дистиляції знань від моделей-вчителів до моделі учня глибокого навчання. *Актуальні проблеми комп'ютерних наук АПКН-2024* : матеріали XVI Всеукр. науково-практ. конф., м. Хмельницький, 15–16 листоп. 2024 р. Хмельницький, 2024. С. 196–199. URL: <https://elar.khmnmu.edu.ua/handle/123456789/17767>

10. Chaban O., Manziuk E. Enhancing medical NLI with integrated domain knowledge and sentiment analysis. *Proceedings of the 12th international conference information control systems & technologies (ICST 2024)* : CEUR-Workshop Proceedings, Odesa, Ukraine, 23–25 September 2024. Aachen, 2024. P. 262–272. URL: <https://ceur-ws.org/Vol-3790/paper23.pdf> (індексована в наукометричній базі Scopus)

Публікації, які додатково відображають наукові результати дисертації

11. Комп'ютерна програма “Інтелектуальна інформаційна система інтеграції знань в моделі штучного інтелекту медичних діагностичних комплексів” :

а. с. 141364 Україна : CR3113021225 / О. Р. Чабан, Е. А. Манзюк, П. М. Радюк. № с202508817 ; заявл. 10.10.2025 ; опубл. 31.01.2026, Бюл. № 97. 20 с. URL: <https://sis.nipo.gov.ua/uk/search/detail/1897624/>

12. 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>

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ.....	19
ВСТУП.....	21
РОЗДІЛ 1. АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ПІДХОДІВ ДО ІНТЕГРАЦІЇ ЗНАНЬ У СИСТЕМИ ШТУЧНОГО ІНТЕЛЕКТУ МЕДИЧНИХ ДІАГНОСТИЧНИХ КОМПЛЕКСІВ	31
1.1. Актуальність застосування діагностичних моделей у системах штучного інтелекту медичних діагностичних комплексів.....	32
1.2. Огляд сучасних підходів систем штучного інтелекту до діагностування захворювань	40
1.2.1 Моделі глибокого навчання для діагностування захворювань	40
1.2.2 Аналіз підходів до інтеграції знань із медичних наборів даних у моделі глибокого навчання.....	44
1.3. Характеристики та формалізація знань предметної області	45
1.4. Постановка задачі дослідження	49
1.5. Висновки до розділу 1	51
РОЗДІЛ 2. МОДЕЛІ ТА МЕТОДИ ПЕРЕДАЧІ ЕКСПЕРТНИХ ЗНАНЬ ДО СИСТЕМИ ШТУЧНОГО ІНТЕЛЕКТУ МЕДИЧНОГО ДІАГНОСТИЧНОГО КОМПЛЕКСУ.....	53
2.1. Метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня.....	53
2.1.1 Математична формалізація задачі адаптації домену в умовах гетерогенності медичних даних.....	54
2.1.2 Структурна організація та алгоритмічна реалізація методу адаптивної дистиляції знань	55
2.1.3 Аналіз обчислювальної складності навчання та оцінювання апаратних вимог для впровадження системи	63
2.2. Метод встановлення смислових зв'язків у медичних текстах через інтеграцію знань предметної області та аналізу клінічної полярності	67
2.2.1 Формалізація задачі та обґрунтування вибору компонентів	68

2.2.2 Структура методу та механізми інтеграції онтологічних знань	71
2.2.3 Алгоритмічне забезпечення аналізу модальності та опрацювання заперечень	76
2.3. Висновки до розділу 2	79
РОЗДІЛ 3. МЕТОДИ ІНТЕГРАЦІЇ ЗНАНЬ ДІАГНОСТИЧНИХ МОДЕЛЕЙ В АРХІТЕКТУРИ ГЛИБОКОГО НАВЧАННЯ МЕДИЧНИХ СИСТЕМ	81
3.1. Формалізація інтеграції апріорних знань у стохастичні моделі	82
3.2. Метод сегментації зображень МРТ серця	84
3.2.1 Формалізація науково-прикладної задачі та обмежень	85
3.2.2 Структура методу та алгоритмічне забезпечення	90
3.2.3 Аналіз обчислювальної стійкості та стратегії мінімізації похибок	94
3.3. Метод ідентифікації патологій серця за зображенням МРТ з використанням графової згорткової мережі, орієнтованої на знання	96
3.3.1 Формалізація задачі реляційної класифікації	97
3.3.2 Структура алгоритмічна реалізація методу ідентифікації патологій серця за зображенням МРТ серця	99
3.3.3 Експериментальна валідація, аналіз стійкості до збурень та інтерпретованість	105
3.4. Висновки до розділу 3	108
РОЗДІЛ 4. ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ТА ВЕРИФІКАЦІЯ МЕТОДІВ ІНТЕГРАЦІЇ ЗНАНЬ У МЕДИЧНІ ДІАГНОСТИЧНІ СИСТЕМИ.....	110
4.1. Архітектура програмного комплексу та методологія експерименту	111
4.1.1 Концептуальна архітектура експериментальної системи	112
4.1.2 Технічні деталі реалізації та середовище виконання	117
4.2. Експериментальне дослідження методу адаптивної дистиляції знань від моделей-вчителів до моделі-учня	119
4.2.1 Експериментальна установка: набори даних та базові моделі	120
4.2.2 Аналіз результатів експериментального дослідження методу адаптивної дистиляції знань	123

4.3. Експериментальне дослідження методу встановлення смислових зв'язків у медичних текстах	128
4.3.1 Експериментальна установка та набори даних.....	128
4.3.2 Результати та аналіз помилок	130
4.4. Експериментальна дослідження методів сегментації та ідентифікації патологій за зображенням МРТ серця	135
4.4.1 Опис експериментального середовища та методології.....	136
4.4.2 Результати та аналіз анатомічної коректності	137
4.5. Комплексний аналіз результатів та обмеження запропонованих методів	144
4.6. Висновки до розділу 4	147
ВИСНОВКИ.....	148
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	151
ДОДАТОК А. СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА	171
ДОДАТОК Б. АКТИ ВПРОВАДЖЕННЯ.....	174
ДОДАТОК В. ПРОГРАМНИЙ КОД.....	177
ДОДАТОК Г. СВІТЛИНИ ІНТЕРФЕЙСУ КОРИСТУВАЧА ПРОГРАМНОГО КОМПЛЕКСУ «IDK MEDICAL AI».....	179

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

КТ	–	Комп'ютерна томографія
ЛШ	–	Лівий шлуночок
Міо	–	Міокард
МРТ	–	Магнітно-резонансна томографія
ПШ	–	Правий шлуночок
ACDC	–	Automated Cardiac Diagnosis Challenge
AI	–	Artificial Intelligence
API	–	Application Programming Interface
ARV	–	Arrhythmogenic Right Ventricular dysplasia
AUC	–	Area Under the Curve
BERT	–	Bidirectional Encoder Representations from Transformers
BI-RADS	–	Breast Imaging Reporting and Data System
CAD	–	Computer-Aided Diagnosis / Detection
CBIR	–	Content-Based Image Retrieval
CNN	–	Convolutional Neural Network
CRF	–	Conditional Random Fields
DANN	–	Domain-Adversarial Neural Network
DCM	–	Dilated Cardiomyopathy
DICOM	–	Digital Imaging and Communications in Medicine
DL	–	Deep Learning
DSC	–	Dice Similarity Coefficient
EGA	–	Expert-Guided Attention
EMTKD	–	Enhanced Multi-Teachers Knowledge Distillation
FHIR	–	Fast Healthcare Interoperability Resources
GAN	–	Generative Adversarial Network
GAP	–	Global Attention Pooling
GCN	–	Graph Convolutional Network
GPU	–	Graphics Processing Unit

HCM	– Hypertrophic Cardiomyopathy
HD95	– Hausdorff Distance 95%
HL7	– Health Level 7
KD	– Knowledge Distillation
KG	– Knowledge Graph
KI-GCN	– Knowledge-Informed Graph Convolutional Network
LSTM	– Long Short-Term Memory
MIMIC-CXR	– Medical Information Mart for Intensive Care Chest X-Ray
MINF	– Myocardial Infarction
MLP	– Multilayer Perceptron
NIfTI	– Neuroimaging Informatics Technology Initiative
NLI	– Natural Language Inference
NLP	– Natural Language Processing
NOR	– Normal
ReLU	– Rectified Linear Unit
RNN	– Recurrent Neural Network
ROC	– Receiver Operating Characteristic
ROI	– Region of Interest
SDF	– Signed Distance Function
SKIF-Seg	– Synergistic Knowledge Integration Framework for Segmentation
SSL	– Self-Supervised Learning
SVM	– Support Vector Machine
TAAC	– Topologically-Aware Anatomical Constraints
UMLS	– Unified Medical Language System

ВСТУП

Актуальність роботи. Сучасний етап розвитку медичної науки та клінічної практики характеризується експоненціальним зростанням обсягів діагностичних даних. Такий стан речей вимагає впровадження новітніх інформаційних технологій, зокрема систем штучного інтелекту, для їхнього опрацювання, аналізу та інтерпретації. Упродовж останніх десятиліть спостерігається помітний прогрес у галузі комп'ютерного виявлення та діагностування, особливо в галузях медичної візуалізації та радіології. Цей технологічний стрибок значно зумовлений розвитком методів глибокого навчання, які продемонстрували здатність апроксимувати складні нелінійні залежності в багатовимірних просторах ознак.

Однак класичні методи, що ґрунтуються виключно на даних, досягли межі своєї ефективності за умов дефіциту анотованих наборів даних, варіативності діагностичного обладнання та наявності «семантичного розриву» між ознаками низького рівня та високорівневими клінічними поняттями. Ігнорування верифікованих медичних знань, як от анатомічних, фізіологічних, патологічних та процедурних, призводить до створення статистичних моделей, що є вразливими до збурень, погано інтерпретованими та схильними до критичних помилок у нестандартних клінічних ситуаціях. Це створює низку системних бар'єрів для впровадження систем штучного інтелекту в процес медичного діагностування, зумовлюючи потребу цілеспрямованого підвищення точності та клінічної обґрунтованості прийнятих рішень.

Вагомий внесок у розроблення моделей, методів та засобів інтелектуального аналізу медичних даних, оброблення зображень та побудови діагностичних систем зробили українські та іноземні вчені: О. М. Березький [1–3], І. В. Ізонін [4, 5], Д. В. Вакуленко [6], О. В. Палагін [7], О. Г. Аврунін [8, 9], Бредлі Еріксон (Bradley Erickson) [10], Герт Літенс (Gert Litjens) [11], Андре Естева (Andre Esteva) [12], Олаф Роннебергер (Olaf Ronneberger) [13].

Дослідженню підходів до інтеграції предметних знань у моделі глибокого навчання, питанням трансферного навчання та дистиляції знань присвячені праці

Сяочжена Се (Xiaozheng Xie) [14], Крістеля Сіроккі (Christel Sirocchi) [15], Фухена Чжана (Fuheng Zhang) [16], Джоффри Гінтона (Geoffrey Hinton) [17], Чаккріта Термрітхікуна (Chakkrit Termritthikun) [18].

Впровадженню графових згорткових мереж для моделювання взаємозв'язків між об'єктами, а також використанню механізмів уваги для фокусування на значущих ознаках присвячені роботи Джошку Оксюза (Coşku Öksüz) [19], Петара Величковіча (Petar Veličković) [20], Муханя Чжана (Muhan Zhang) [21], Цзичао Хуана (Zichao Huang) [22], Соум'я Шарми (Soumya Sharma) [23].

Попри велику кількість проведених наукових досліджень у галузі медичного штучного інтелекту, наявні підходи здебільшого є фрагментарними та не забезпечують системного врахування експертного досвіду в архітектурі нейронних мереж. Класичні моделі глибокого навчання значно деградують в умовах гетерогенності джерел та обмеженої розмітки, що унеможлиблює їхнє безпечне клінічне використання. З огляду на це, актуальною науково-прикладною задачею є підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах. Розв'язання цієї задачі вбачається в створенні гібридних моделей, які інтегрують формалізовані експертні знання в моделі глибокого навчання на етапах сегментації, класифікації та аналізу текстових даних, доповнюючи статистичне навчання.

Зв'язок роботи з науковими програмами, планами, темами. Дисертаційну роботу виконано, відповідно до плану науково-дослідної тематики Хмельницького національного університету. Здобувач був безпосереднім виконавцем держбюджетної науково-дослідної теми ГУ 57-2024 «Інтелектуальна система розпізнавання дефектів об'єктів зеленої енергетики із використанням БПЛА» (№ державної реєстрації 0124U004665). Фінансове забезпечення цього проєкту здійснюється коштом зовнішнього інструменту допомоги Європейського Союзу, що спрямоване на реалізацію зобов'язань України в рамках програми Європейського Союзу із наукових досліджень та інновацій «Горизонт 2020».

Мета й завдання дослідження.

Об'єктом дослідження є процеси інтеграції знань та опрацювання даних у системах штучного інтелекту медичних діагностичних комплексів.

Предметом дослідження є методи та засоби інтеграції експертних знань у моделі глибокого навчання для задач сегментації, класифікації медичних зображень та аналізу текстових клінічних даних.

Метою дослідження є підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах через створення методів та засобів інтеграції експертних знань у моделі штучного інтелекту.

Для досягнення мети сформульовано такі **завдання**.

1. Провести аналіз сучасного стану методів глибокого навчання та підходів до формалізації медичних знань, виявити наявні обмеження статистичних підходів та визначити перспективи створення гібридних архітектур.

2. Розробити метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня для забезпечення точності процесу діагностування в умовах зсуву домену та обмеженої розмітки даних.

3. Розробити метод встановлення смислових зв'язків у медичних текстах через інтеграцію онтологічних знань та аналізу тональності в архітектуру нейронної мережі для підвищення точності інтерпретації клінічних записів.

4. Розробити метод сегментації зображень магнітно-резонансної томографії серця, що ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги та спеціалізованої функції втрат із топологічними обмеженнями для забезпечення анатомічної коректності результатів.

5. Розробити метод ідентифікації патологій із використанням графової згорткової мережі, який інтегрує реляційні діагностичні знання та дає змогу моделювати взаємозв'язки між анатомічними структурами.

6. Спроекувати архітектуру інтелектуальної інформаційної системи інтеграції знань, яка забезпечує гнучке оброблення гетерогенних медичних даних та підтримку модульної взаємодії між компонентами сегментації, класифікації та аналізу текстів.

7. Виконати програмну реалізацію інтелектуальної інформаційної системи інтеграції знань на основі спроектованої архітектури, здійснити постановку експерименту та провести комплексні експериментальні дослідження для підтвердження підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах на еталонних медичних наборах даних.

Методи дослідження. Для розв'язання поставлених завдань у дисертації використано: методи глибокого навчання та теорії нейронних мереж – для розпізнавання образів та оброблення природної мови; методи інженерії знань – для формалізації медичних онтологій та експертних правил; теорію графів та графові нейронні мережі – для моделювання зв'язків між анатомічними структурами та діагнозами; методи математичної статистики – для аналізу розподілу даних та оцінювання достовірності результатів експериментів; методи оптимізації – для налаштування параметрів моделей.

Наукова новизна отриманих результатів полягає в такому.

1. Удосконалено метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня, який відрізняється від аналогів використанням динамічного ансамблю моделей-вчителів зі спеціалізованою моделлю для змагальної адаптації домену та механізмом селективної фільтрації, що дає змогу накопичувати досвід із різних клінічних доменів та передавати його компактній моделі-учню, підвищуючи в такий спосіб точність процесу прийняття рішень за варіативності вхідних даних.

2. Удосконалено метод встановлення смислових зв'язків у медичних текстах, який, на відміну від наявних, поєднує інтеграцію онтологічних знань та явне кодування інформації про тональність і заперечення, що підвищує точність інтерпретації клінічних записів та забезпечує логічну узгодженість висновків.

3. Розроблено новий метод сегментації зображень магнітно-резонансної томографії серця, який ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги для фокусування на складних ділянках та спеціалізованої функції втрат із топологічними обмеженнями на основі знакової відстані, який, на відміну від наявних підходів, дає змогу явно кодувати вкладеність

та суміжність анатомічних структур, що забезпечує підвищення точності визначення меж органів та усунення топологічних артефактів.

4. Розроблено новий метод ідентифікації патологій серця за зображенням магнітно-резонансної томографії із використанням графової згорткової мережі, орієнтованої на знання, який, на відміну від відомих рішень, реалізує парадигму реляційного міркування на графах, де вузли об'єднують гібридні візуальні та морфологічні ознаки, а матриця суміжності формується як суперпозиція просторових зв'язків та клінічних кореляцій із медичних настанов, що дає можливість підвищити точність класифікації діагнозів та забезпечити інтерпретованість прийнятих рішень.

Обґрунтованість і достовірність наукових положень, висновків і рекомендацій. Достовірність результатів підтверджується коректним використанням математичного апарату, системним аналізом сучасних підходів, збіжністю теоретичних оцінок із результатами експериментальних досліджень на різноманітних еталонних наборах даних, а також впровадженням розроблених методів у вигляді програмного комплексу. Статистична значущість покращення метрик якості підтверджена порівняльним аналізом із сучасними аналогами.

Практичне значення отриманих результатів. На основі запропонованих у дисертаційній роботі методів та моделей розроблено та програмно реалізовано інтелектуальну інформаційну систему, яка забезпечує опрацювання, інтеграцію та аналіз гетерогенних медичних даних, як от зображень, текстових записів та онтологій. Практична цінність роботи обумовлена результативністю застосування розроблених компонентів системи до клінічних та діагностичних процесів, що безпосередньо забезпечують підвищення точності та клінічної обґрунтованості процесу прийняття рішень.

Підвищення точності процесу прийняття рішень досягнуто завдяки комплексному впровадженню нейромережових методів аналізу візуальних даних та їхній стійкості до доменних зсувів. Зокрема, розроблений метод сегментації зображень магнітно-резонансної томографії серця з інтеграцією топологічних обмежень на основі знакових відстаней забезпечив прецизійну морфометрію:

метрику відстані Хаусдорфа для міокарда зменшено з 9,8 мм до 6,5 мм, а коефіцієнт Дайса для лівого шлуночка досяг 95,5 %. Впровадження методу ідентифікації патологій серця за зображенням магнітно-резонансної томографії із використанням графової згорткової мережі, що об'єднує просторові та гібридні ознаки, дало змогу підвищити загальну точність ідентифікації патологій серця до 94,0 %. Водночас збереження високого рівня точності під час роботи з гетерогенним обладнанням досягається застосуванням удосконаленого методу адаптивної дистиляції знань. Так, впровадження методу дало можливість досягти показника точності класифікації (AUC-ROC) 81,45 % на новому цільовому домені за наявності лише 500 розмічених зразків, що перевищує результати базових методів трансферного навчання на 4,35–4,95 %.

Підвищення клінічної обґрунтованості процесу прийняття рішень реалізовано через забезпечення топологічної, логічної та семантичної достовірності результатів на всіх етапах прийняття рішень. Впровадження методу встановлення смислових зв'язків у медичних текстах із використанням онтологій та явного кодування тональності й заперечень підвищило точність логічного виведення на еталонному наборі MedNLI до 81,14 %. Це забезпечило зростання повноти виявлення клінічних суперечностей у неструктурованих медичних записах до 85 %, нівелюючи ризик хибних висновків. Анатомічна достовірність результатів гарантується зниженням топологічних дефектів сегментації, зокрема, зменшенням розривів контуру міокарда з 10,5 % до 4,1 %. Крім того, клінічна прозорість підсумкових діагнозів забезпечується здатністю моделі класифікації графової згорткової мережі через механізм глобальної субдискретизації уваги надавати інтерпретовані результати, які дають змогу лікарю об'єктивно відстежити та верифікувати логіку системи.

Теоретичні та практичні результати дослідження впроваджені та використовуються у:

– Львівському торговельно-економічному університеті (акт впровадження від 28.10.2025): матеріали дисертації впроваджено в навчальний процес кафедри комп'ютерних наук, прикладної та вищої математики при викладанні дисциплін

«Інтелектуальний аналіз даних» та «Методи та системи штучного інтелекту» для здобувачів вищої освіти спеціальності 122 «Комп'ютерні науки»;

– Хмельницькій інфекційній лікарні (акт впровадження від 12.11.2025): результати дисертації використано для удосконалення процесів діагностики та автоматизованого аналізу анонімізованих даних ультразвукових досліджень серця, що дало змогу підвищити оперативність та точність прийняття рішень лікарями-діагностами;

– ТОВ «КЦ НЕЙРОН» (акт впровадження від 22.10.2025): запропоновані методи використано в процесі впровадження прототипів нових програмних застосунків з інтеграцією систем штучного інтелекту, зокрема модулів інтелектуального аналізу даних та систем підтримки прийняття рішень;

– Хмельницькому національному університету в процесі виконання держбюджетної теми ГУ 57-2024 «Інтелектуальна система розпізнавання дефектів об'єктів зеленої енергетики із використанням БПЛА» (№ держреєстрації 0124U004665).

Світлини актів впровадження результатів дослідження подано в додатку Б.

Особистий внесок здобувача. Усі наукові результати, викладені в дисертації, отримані автором самостійно. У роботах, що опубліковані автором одноосібно, отримано такі результати: [24] – виконано ґрунтовний аналітичний огляд сучасного стану технологій штучного інтелекту в медицині, визначено основні проблеми та окреслено перспективи інтеграції діагностичних моделей; [25] – запропоновано метод інтеграції доменних знань на основі графових нейронних мереж для сегментації зображень магнітно-резонансної томографії серця; [26] – розроблено підхід поєднання контекстних векторних представлень слів із векторним поданням медичного домену.

У роботах, які опубліковані в співавторстві, автору належать основні ідеї, теоретичне та практичне розроблення положень, що відображені в характеристиці наукової новизни отриманих результатів, а саме: [27] – удосконалено метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня глибокого навчання, проведено експериментальні дослідження та аналіз результатів; [28] –

запропоновано метод інтегрування доменних знань у багатостратегічну класифікацію медичних зображень; [29] – спроектовано архітектуру інтелектуальної інформаційної системи інтеграції знань у моделі штучного інтелекту; [30] – запропоновано метод ідентифікації патологій серця за зображенням магнітно-резонансної томографії на основі графових нейронних мереж; [31] – реалізовано адаптивну дистиляцію знань для класифікації зображень магнітно-резонансної томографії серця на периферійних пристроях; [32] – розроблено підхід до інтегрування експертних знань у модель U-Net для сегментування зображень; [33] – досліджено метод адаптивної дистиляції знань та його ефективність; [34] – удосконалено метод встановлення смислових зв'язків у медичних текстах через інтеграцію доменних знань та аналізу тональності; [35] – виконано програмну реалізацію інтелектуальної інформаційної системи та отримано авторське свідоцтво на комп'ютерну програму.

Особистий внесок співавторів у спільних публікаціях є таким: [27] – Е. Манзюк, як науковий керівник, здійснив загальне керівництво дослідженням, сформулював методологічну концепцію методу адаптивної дистиляції знань та визначив стратегію валідації результатів, П. Радюк виконав програмну реалізацію модулів навчання ансамблю вчителів і моделі-учня, а також провів комплексні обчислювальні експерименти для оцінки точності на різних наборах даних; [28] – Е. Манзюк надав наукові консультації щодо теоретичних принципів інтеграції доменних знань у класифікаційні моделі глибокого навчання, О. Дука брала безпосередню участь у підготовці, очищенні та попередній обробці наборів медичних зображень для забезпечення якості експериментальної перевірки; [29] – Е. Манзюк брав участь у проектуванні високорівневої архітектури інтелектуальної системи та визначенні її компонентів, П. Радюк розробив програмний модуль для стандартизованої обробки, конвертації та анонімізації даних у форматах DICOM та NIfTI, О. Зайцева та О. Маркевич надали фахові консультації щодо медичних аспектів, сформулювали клінічні вимоги до системи та критерії валідності діагностичних висновків; [30] – Е. Манзюк консультував із питань архітектурних особливостей використання графових нейронних мереж для задач медичної

діагностики, П. Радюк допоміг із технічним налаштуванням гіперпараметрів нейромережевої моделі за методом ідентифікації патологій серця та оптимізацією процесу навчання, О. Маркевич надала верифіковані клінічні дані магнітно-резонансної томографії та здійснила експертну оцінку отриманих результатів сегментації, С. Петровський виконав детальне анотування медичних даних та провів статистичний аналіз обчислювальних результатів; [31] – Е. Манзюк провів наукове керівництво над дослідженням методів адаптивної дистиляції для обмежених периферійних пристроїв, О. Маркевич надала консультації щодо специфіки класифікації рідкісних патологій серця на зображенні магнітно-резонансної томографії, С. Петровський виконав порівняльний аналіз результатів роботи моделі в умовах зміщення домену, П. Радюк брав участь у програмній реалізації алгоритму адаптивного зважування вчителів та механізму псевдоміток; [32] – Е. Манзюк надав консультації щодо модифікації базової архітектури U-Net механізмами просторової уваги для покращення фокусування на дрібних деталях; [33] – Е. Манзюк брав участь в аналітичному обговоренні та інтерпретації результатів адаптивної дистиляції знань; [34] – Е. Манзюк консультував щодо вибору методів аналізу тональності в неструктурованих медичних текстах; [35] – Е. Манзюк та П. Радюк брали безпосередню участь у розробці та кодуванні окремих програмних модулів системи як співавтори зареєстрованого твору.

Апробація результатів дисертації. Основні положення та результати роботи доповідалися та обговорювалися на міжнародних та всеукраїнських науково-практичних конференціях, зокрема: 2nd International Workshop on Advanced Applied Information Technologies (Khmelnyskyi, 2025); 8th International Conference on Informatics & Data-Driven Medicine (Lviv, 2025); 5th Edge Computing Workshop (Zhytomyr, 2025); XVI Всеукраїнській науково-практичній конференції «Актуальні проблеми комп'ютерних наук АПКН-2024» (Хмельницький, 2024); 12th International Conference Information Control Systems & Technologies (Odesa, 2024); XXII Міжнародній науковій конференції «Нейромережні технології та їх застосування НМТЗ-2024» (Краматорськ-Тернопіль, 2024).

Публікації. За темою дисертації опубліковано 12 наукових праць ([24–35] та додаток А), з них: 1 стаття в періодичному виданні, що індексується в наукометричній базі Scopus [27]; 3 статті у фахових наукових виданнях України [25, 26, 28] категорії Б; 6 праць у матеріалах міжнародних та всеукраїнських конференцій [29–34], які засвідчують апробацію матеріалів дисертації, поміж яких 2 праці індексовані в наукометричній базі Scopus та/або Web of Science [31, 34]; 1 свідоцтво про реєстрацію авторського права на твір (комп'ютерна програма) [35]; 1 розділ у колективній монографії [24].

Структура та обсяг дисертації. Дисертаційна робота складається з анотації, змісту, переліку умовних скорочень, вступу, чотирьох розділів, висновку, списку використаних джерел та п'яти додатків. Загальний обсяг дисертаційної роботи становить 182 сторінки друкованого тексту, з них анотація – на 14 стор., зміст – на 3 стор., перелік умовних скорочень – на 2 стор., основний текст – на 130 стор., список зі 142 використаних джерел – на 20 стор., додатки – на 12 стор. Дисертація містить 54 рисунки та 27 таблиць.

РОЗДІЛ 1.

АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ПІДХОДІВ ДО ІНТЕГРАЦІЇ ЗНАНЬ У СИСТЕМИ ШТУЧНОГО ІНТЕЛЕКТУ МЕДИЧНИХ ДІАГНОСТИЧНИХ КОМПЛЕКСІВ

У першому розділі дисертаційної роботи здійснено комплексний аналіз сучасного стану технологій штучного інтелекту в медичній сфері, з акцентом на радіологію та візуалізацію. За результатами огляду наукових джерел доведено, що класичні методи глибокого навчання, які ґрунтуються виключно на статистичному опрацюванні даних, вичерпують свій потенціал. Це зумовлено дефіцитом анотованих баз даних та високою варіативністю діагностичного обладнання. У розділі систематизовано проблеми галузі: явище доменного зсуву, семантичний розрив між ознаками низького рівня та клінічними поняттями, а також проблему «чорної скриньки»: відсутність прозорої інтерпретованості рішень, що є суттєвою перешкодою для клінічної практики.

Крім того, детально розглянуто сучасні підходи до інтеграції знань: трансферне навчання, механізми уваги та застосування графів знань. Встановлено, що наявні нині методи переважно є фрагментарними. Вони не здатні забезпечити системного врахування експертного досвіду (анатомічних, процедурних та онтологічних закономірностей) безпосередньо в архітектурі нейронних мереж. Цей аналіз дав змогу науково обґрунтувати потребу переходу до розроблення гібридних архітектур, що синергетично поєднують результативність глибокого навчання з формалізованими медичними знаннями.

Узагальнення виявлених недоліків стало підставою для формулювання мети й завдань дослідження. Було визначено вимоги до перспективних моделей: вони мають гарантувати стійкість до збурень, забезпечувати анатомічну коректність результатів сегментації, володіти здатністю до реляційного міркування під час ідентифікації патологій та здійснювати точну й узгоджену інтерпретацію текстових клінічних записів.

1.1. Актуальність застосування діагностичних моделей у системах штучного інтелекту медичних діагностичних комплексів

Сучасний етап розвитку медичної науки та клінічної практики характеризується експоненціальним зростанням обсягів діагностичних даних, що вимагає впровадження нових інформаційних технологій для їхнього опрацювання, аналізу та інтерпретації. Упродовж останніх десятиліть спостерігається фундаментальний прогрес у галузі комп'ютерного виявлення та діагностування (англ. «Computer-aided Detection and Diagnosis», CAD), особливо в галузях медичної візуалізації та радіології. Цей технологічний стрибок значно зумовлений розвитком методів глибокого навчання (англ. «Deep Learning», DL), які продемонстрували здатність апроксимувати складні нелінійні залежності в багатовимірних просторах ознак [10, 11]. У роботах [36, 37] зазначається, що цей вплив поширюється на стаціонарні системи та мобільні й бездротові мережі передачі медичних даних, що актуалізує питання створення ефективних, але компактних діагностичних моделей.

Досягнувши успіхів у класичних задачах комп'ютерного зору, різноманітні архітектури моделей DL, переважно глибокі згорткові нейронні мережі (англ. «Convolutional Neural Network», CNN) та новітні трансформерні архітектури, були успішно адаптовані до специфіки медичних зображень. Проте, пряме перенесення методів із загального домену в медичний часто стикається з проблемою недостатньої надійності [38]. Спектр застосувань охоплює важливі напрями, включно з раннім виявленням раку молочної залози на мамограмах, де значний внесок зробили дослідження [39], що фокусуються на виявленні мікрокальцинатів. Уваги заслуговують методи ідентифікації легеневих вузликів на зображеннях комп'ютерної томографії (КТ), що подані в працях [40, 41], які демонструють високу чутливість, але часто страждають від високого рівня хибнопозитивних результатів. Також активно розвиваються підходи до діагностування глаукоми за зображеннями очного дна [42, 43] та дерматоскопічний аналіз новоутворень шкіри [12, 44].

Однак здебільшого такі системи розглядають процес діагностування як статистичну задачу відображення вхідного сигналу у вихідну мітку, ігноруючи причинно-наслідкові зв'язки та медичний контекст. У найбільш загальному вигляді інтелектуальну систему CAD, побудовану на основі методів глибокого навчання, можна формалізувати як параметричну функцію відображення f_{CAD} , що трансформує вхідний простір сенсорних даних у простір клінічних рішень (рис. 1.1).

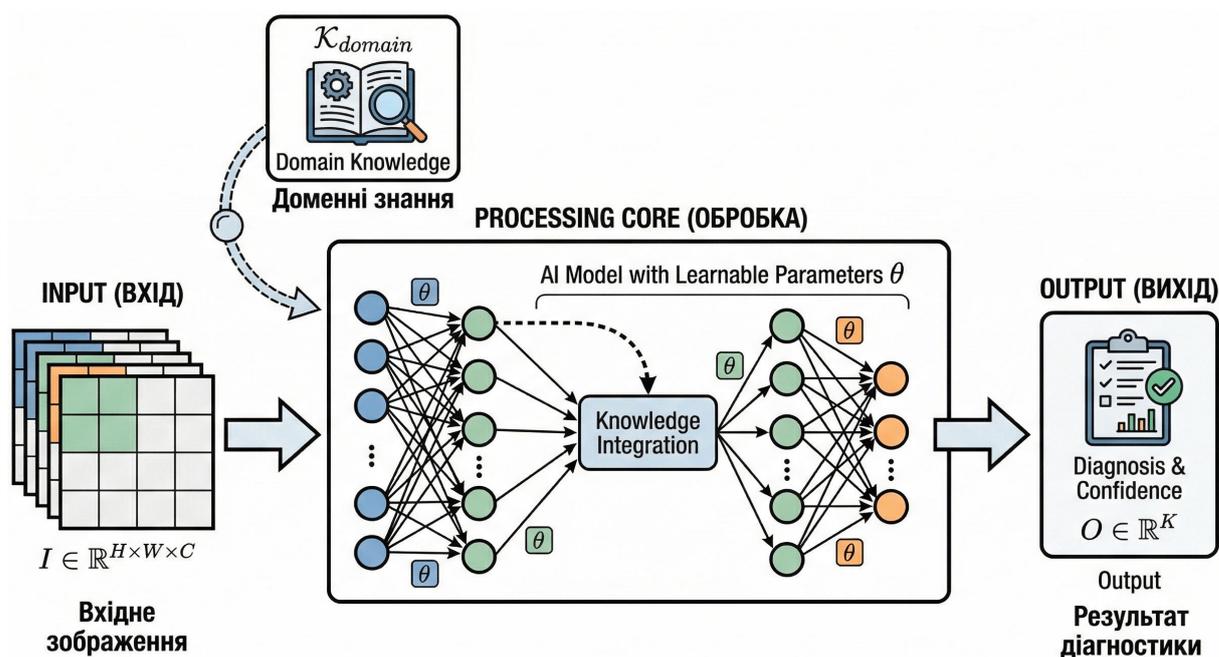


Рисунок 1.1 – Концептуальна схема інтелектуальної системи CAD: трансформація вхідних сенсорних даних у простір рішень з урахуванням доменних знань

Нехай $I \in \mathbb{R}^{H \times W \times C}$ – вхідне медичне зображення (або тензор мультимодальних даних), $\theta \in \mathbb{R}^d$ – вектор параметрів моделі, що навчаються, а \mathcal{K}_{domain} – структуроване представлення апріорних знань предметної області. Тоді процес діагностування описується формулою:

$$D = f_{CAD}(I; \theta, \mathcal{K}_{domain}), \quad (1.1)$$

де D позначає вихідний діагностичний результат, який може набувати форми вектора ймовірностей класів (класифікація), маски сегментації (локалізація) або координат обмежувальних рамок (виявлення).

Введення компоненти $\mathcal{K}_{\text{domain}}$ у формулу (1.1) є принциповим моментом, що відрізняє запропонований підхід від стандартних методів, де процес діагностування розглядається як $D = f(I; \theta)$. Крім того, важливість інтеграції компоненти $\mathcal{K}_{\text{domain}}$ у формулі (1.1) для підвищення надійності систем підтверджується в систематичних оглядах [14, 15]. Без явного врахування знань модель θ змушена вивчати ці закономірності неявно з навчальної вибірки, що вимагає величезних обсягів даних, яких у медицині часто немає.

Важливим аспектом, що відрізняє медичні системи штучного інтелекту (англ. «Artificial Intelligence», AI) від систем загального призначення, є необхідність інтеграції знань для подолання обмежень «чистих» даних. У класичному глибокому навчанні модель намагається вивести всі необхідні закономірності виключно з навчальної вибірки даних. Однак, як зауважують автори [19, 45], у медицині є значні обсяги верифікованих знань – анатомічних, фізіологічних, патологічних та процедурних, – ігнорування яких призводить до створення моделей, що є нестійкими, погано інтерпретованими та схильними до помилок у нестандартних клінічних ситуаціях. Це створює низку системних проблем при впровадженні AI в процес діагностування, які деталізовано в табл. 1.1.

Практична реалізація підходу інтеграції знань стикається з фундаментальною проблемою дефіциту даних. Невеликий розмір верифікованих медичних наборів даних створює суттєвий бар'єр для отримання задовільних моделей DL, оскільки, згідно з дослідженнями [46], здатність моделі до узагальнення корелює з обсягом навчальної вибірки. У традиційних задачах комп'ютерного зору є еталонні набори даних, такі як ImageNet (понад 14 мільйонів анотованих зображень). На відміну від цього, загальнодоступні медичні набори даних є значно меншими, що вимагає специфічних методів адаптації, таких як навчання з малою кількістю прикладів або адаптація без доступу до вихідного домену [47]. Цей дисбаланс призводить до того,

що емпіричний ризик $\mathcal{R}_{\text{emp}}(f_{\text{CAD}}; S_{\text{med}})$ перестає бути надійною оцінкою істинного ризику $\mathcal{R}_{\text{true}}(f_{\text{CAD}})$, що спричиняє явище перенавчання.

Таблиця 1.1

Системні проблеми та бар'єри, що виникають при використанні штучного інтелекту в діагностичних галузях медицини [24]

Чинник впровадження AI	Проблема
Приватність та кібербезпека	Необхідний надійний захист від зовнішнього втручання в технологічну систему діагностичних центрів для збереження всіх даних пацієнтів. Уникнення можливості помилок діагностичних систем AI (фальсифікація або зміна даних).
Надійність	Проблеми з технологією можуть вплинути на кінцевий результат і діагноз. Якісне формулювання процесів і завдань AI, своєчасний аналіз та контроль рівня результатів безпосередньо впливають на правильне виконання завдань.
Технологія та відповідальність	Постійно виникають питання про технічні, етичні та управлінські компоненти технологій на основі AI. Хто нестиме відповідальність за діагностичні помилки?
Автономія та система підтримки	Громадськість має доступ до сучасних додатків, що використовуються в медицині. Коли виникає потреба, людина може змінити результати, що вплине на кінцевий продукт.
Етнічні групи населення	Не всі країни та не всі медичні діагностичні заклади здатні мати відповідне матеріально-технічне підґрунтя для технологій AI. Недостатнє фінансування охорони здоров'я.
Технологічна база	Розробленням технологій AI здебільшого займаються люди без медичної освіти, тому можуть виникати питання щодо медичних помилок. Вони не можуть бути виправлені медичним персоналом, що призведе до неякісного результату.

Ілюстрацією цієї проблеми є статистика доступних наборів даних, що проілюстровано на рис. 1.2.

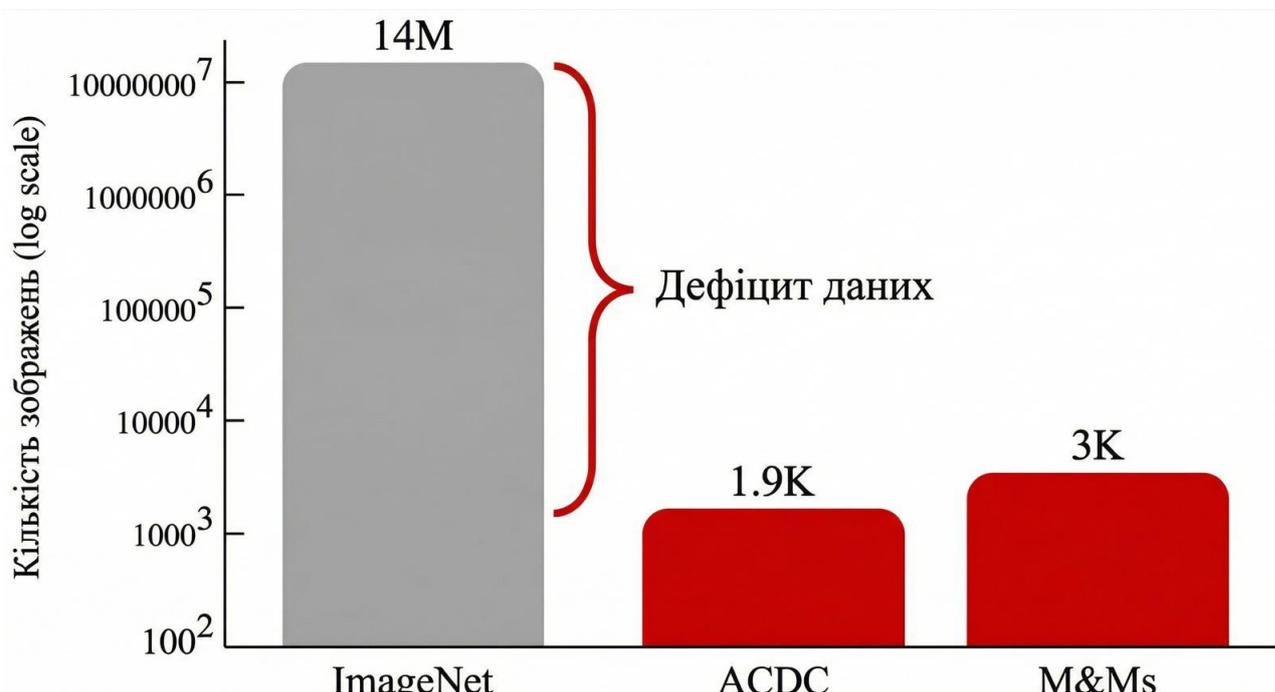


Рисунок 1.2 – Порівняльна характеристика обсягів даних у загальних наборах комп'ютерного зору (ImageNet) та спеціалізованих медичних наборах (ACDC та M&Ms), що ілюструє проблему дефіциту даних

Поміж множини наявних ресурсів лише окремі містять понад 100 000 зображень. До таких належать ChestX-ray14 [48] та CheXpert [49]. Також варто виділити набори PadChest [50] та DeepLesion [51], які забезпечують значний обсяг даних для навчання. Для аналізу звітів радіологів важливим є ресурс MIMIC-CXR [52], що поєднує зображення та текстові описи. У галузі діагностування захворювань серця за зображеннями магнітно-резонансної томографія (МРТ) значними є ініціативи CMRxMotion [53] та CMRxRecon [54], що надають дані для задач реконструкції та аналізу руху. Однак навіть ці «великі» за медичними мірками набори є незначними з даними, на яких навчаються сучасні базові моделі. Детальний розподіл та характеристики найбільш релевантних медичних наборів даних наведено в табл. 1.2.

Таблиця 1.2

Аналіз наборів даних, що використовуються для розв'язання різних завдань
опрацювання медичних зображень

Назва набору даних	Завдання	Медичний фокус	Тип даних	Кількість
ChestX-ray14 [48]	Виявлення	Грудна клітка	Рентген	112 120 зображень
CheXpert [49]	Класифікація	Грудна клітка	Рентген	224 316 зображень
DeepLesion [51]	Класифікація, Виявлення	Різні	КТ	32 735 зображень
MIMIC-CXR [52]	Генерація звітів	Грудна клітка	Рентген / Текст	377 110 зображень
Cardiac MRI [55]	Класифікація, Сегментація	Серцево-судинна	МРТ	7980 зображень з 33 сканів
ABIDE [56]	Класифікація	Мозок	МРТ	539 пацієнтів та 573 скани
ADNI [57]	Класифікація	Мозок	Різні	1921 пацієнт
LDCT-IQ [58]	Оцінка якості	Торакальна/ Абдомінальна	КТ	Різні дози
BraTS2021 [59]	Сегментація	Мозок	МРТ	542 зображення

Проблема дефіциту даних у медичній галузі має системний характер і проявляється в трьох взаємопов'язаних аспектах. По-перше, абсолютна кількість зображень є обмеженою через високу вартість та складність процедур збору даних, як КТ та МРТ. По-друге, є нестача якісних анотацій, що вимагають експертних знань. По-третє, спостерігається значний дисбаланс класів, особливо для рідкісних патологій. Це питання детально розглядається щодо так званого «довгого хвоста» розподілу даних у роботах [16, 60].

Прямим наслідком цих обмежень є схильність глибоких моделей до перенавчання [61]. Математично перенавчання визначається як значна розбіжність між значенням функції втрат на навчальній та тестовій вибірках. Нехай $\mathcal{L}(y, \hat{y})$ – функція втрат, наприклад, перехресна ентропія або відстань Хаусдорфа, яка є специфічною для задач сегментації [62]. Умова перенавчання записується як:

$$\mathbb{E}_{(x,y) \sim S_{\text{train}}} [\mathcal{L}(y, f_{\text{CAD}}(x; \theta))] \ll \mathbb{E}_{(x,y) \sim S_{\text{test}}} [\mathcal{L}(y, f_{\text{CAD}}(x; \theta))]. \quad (1.2)$$

Нерівність (1.2) вказує на те, що модель запам'ятала шум навчальної вибірки замість вивчення генеральних закономірностей. Для боротьби із цим явищем у комп'ютерному зорі розроблено низку методів регуляризації. Поміж них – методи оптимізації, такі як Adam [63], зменшення місткості мережі, та стохастична регуляризація. Важливу роль відіграє аугментація даних, яка може бути реалізована за допомогою генеративних змагальних мереж (ГЗМ) [64] або методів доменно-змагального навчання [65].

Однак зазначені методи є суто статистичними інструментами. За умови дефіциту медичних даних та необхідності високої надійності, більш перспективним підходом є інтеграція зовнішніх знань, що дає змогу компенсувати нестачу навчальних прикладів через звуження простору пошуку рішень. Попри наявні перешкоди, інтеграція діагностичних моделей демонструє потенціал для значного підвищення ефективності, що підтверджується результатами останніх досліджень (див. табл. 1.3).

Ідея використання зовнішньої інформації реалізується через різні механізми. Найпоширенішим є трансферне навчання [66, 67], де модель попередньо навчається на масивному наборі даних. Отримані параметри слугують початковою точкою для навчання на цільовому медичному наборі. Цей підхід продемонстрував ефективність у задачах класифікації раку простати [68] та виявленні патологій на трансректальному ультразвуці [69]. Для ефективної адаптації часто використовують дистиляцію знань, огляд методів якої наведено в роботі [70].

Таблиця 1.3

Показники результативності інтегрованих діагностичних моделей AI, що демонструють потенціал гібридних підходів [16]

Метрика	Значення
Чутливість (англ. «sensitivity»)	94,5%
Специфічність (англ. «specificity»)	92,3%
Загальна класифікація	93,8%
Інтерпретованість	Покращене розуміння процесу прийняття рішень системою AI

Окрім трансферного навчання, важливим джерелом є знання предметної області, які можна класифікувати за рівнем абстракції. Високорівневі знання включають діагностичні протоколи та таксономії захворювань [71, 72]. Низькорівневі знання охоплюють інформацію про анатомічну локалізацію та морфологічні ознаки [73]. Для завдань сегментації важливими є апіорні знання про форму та взаємне розташування органів [74, 75].

Сучасні методи інтеграції знань включають гібридні архітектури, що поєднують глибокі нейронні мережі з традиційними методами [76]. Якщо позначити h_{TH} як вектор ознак із моделі DL, а h_{HC} як вектор, розрахований на основі експертних правил (наприклад, форми або текстури [77, 78]), то об'єднаний дескриптор використовується для прийняття рішення. Більш комплексні підходи використовують механізми уваги [79] для імітації шаблонів візуального пошуку радіолога [80, 81]. Карта уваги модулює просторові ознаки, посилюючи сигнал від релевантних зон. Також застосовуються багатозадачне навчання [19] та метанавчання [82].

Попри наявність оглядових праць із медичного глибокого навчання, є потреба в систематизації методів саме в контексті інтеграції експертних знань. На рис. 1.3 проілюстровано концептуальну таксономію підходів до цієї проблеми.

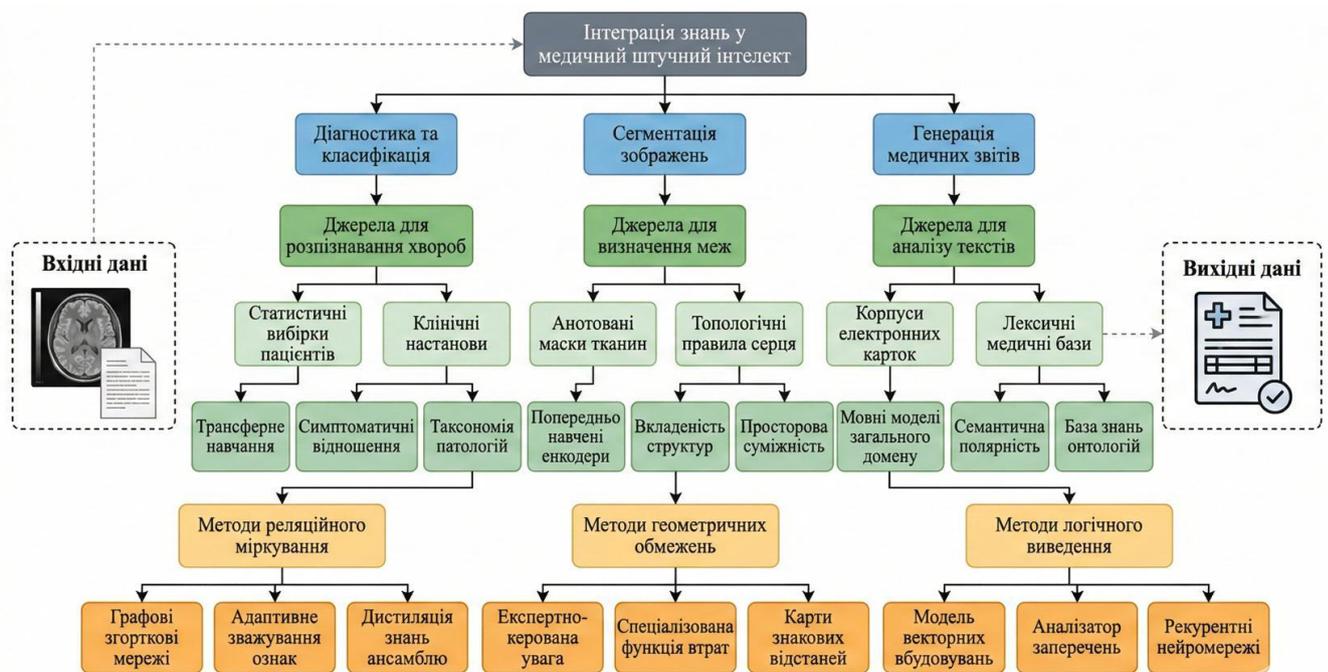


Рисунок 1.3 – Категоризація знань та методів для діагностування захворювань: ієрархія завдань та джерел додаткової інформації

На верхньому рівні цієї схеми дослідження класифікуються за клінічними завданнями: 1) діагностування (класифікація) захворювань; 2) виявлення анатомічних структур та аномалій; 3) сегментація органів та уражень.

1.2. Огляд сучасних підходів систем штучного інтелекту до діагностування захворювань

Задача діагностування захворювань засобами штучного інтелекту формалізується як проблема класифікації вхідного зображення I до одного з класів множини $\mathcal{C} = \{c_1, c_2, \dots, c_K\}$, що відображають можливі патологічні стани або норму.

1.2.1 Моделі глибокого навчання для діагностування захворювань

Упродовж останнього десятиліття панівним підходом у цій галузі стали CNN, принципи яких були закладені у фундаментальних роботах [17]. Архітектура CNN

ґрунтується на принципах, запозичених із біології, організації зорової кори, зокрема на наявності рецептивних полів та ієрархічній обробці інформації [83].

Математично згортковий шар l виконує перетворення вхідного тензора ознак $F^{(l-1)}$ у вихідний тензор $F^{(l)}$ за допомогою операції згортки з набором ядер (фільтрів) $W^{(l)}$ та додавання зміщення $b^{(l)}$, з подальшим застосуванням нелінійної функції активації σ :

$$F_k^{(l)}(i, j) = \sigma \left(\sum_c \sum_{u, v} W_{k,c}^{(l)}(u, v) \cdot F_c^{(l-1)}(i - u, j - v) + b_k^{(l)} \right), \quad (1.3)$$

де k – індекс вихідної карти ознак, c – індекс вхідного каналу, (u, v) – просторові координати ядра.

Функція активації $\sigma(\cdot)$ у формулі (1.3) забезпечує нелінійність моделі, що є суттєвим для вивчення складних залежностей. Для зменшення розмірності даних використовуються шари субдискретизації (англ. «pooling»):

$$P_k^{(l)}(i, j) = \max_{(u, v) \in \Omega(i, j)} F_k^{(l)}(u, v). \quad (1.4)$$

Глибока архітектура формується через каскадне з'єднання блоків «згортка-субдискретизація» (див. формулу (1.4)). Останній шар зазвичай використовує функцію Softmax для генерації розподілу ймовірностей у над класами діагнозів:

$$y_k = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}},$$

де z_k – логіт для класу k .

Еволюція архітектур CNN, починаючи від VGGNet [84] до більш сучасних ResNet [85] та DenseNet [86], дала змогу значно підвищити точність діагностування. Зокрема введення залишкових зв'язків у ResNet дало можливість ефективно навчати надглибокі мережі, вирішуючи проблему «загасання градієнта». У медичних застосуваннях ці архітектури стали базовими. Наприклад, вони успішно

застосовуються для діагностування виразкового кератиту [87] та виявлення легеневих вузликів [40, 88].

Для завдань сегментації, які вимагають піксельної точності, використовуються спеціалізовані архітектури, такі як U-Net [13] та її модифікації nnU-Net [89]. Ці мережі використовують архітектуру кодувальник-декодувальник зі пропусковими зв'язками, що дає змогу зберігати просторову інформацію. Такими прикладами є R2U-Net [90], яка поєднує рекурентні та залишкові блоки, та методи для сегментації пухлин мозку [91, 92]. У роботах [93, 94] продемонстровано ефективність глибоких мереж для сегментації гіперінтенсивності білої речовини та неонатального мозку відповідно.

Важливим аспектом сучасних досліджень є використання ГЗМ та дифузійних моделей. Варто зазначити, що моделі на зразок DAGAN [95] використовуються для аугментації медичних даних та адаптації домену. Генерація синтетичних зразків рідкісних патологій дає змогу вирівняти баланс класів [96], а перенесення стилю допомагає зменшити розрив між даними з різних сканерів [97]. Отже, метод працює з готовими зображеннями для задач сегментації та класифікації, використовуючи генеративні підходи як допоміжний інструмент навчання.

У цифровій патології (гістології) методи аналізу мають свою специфіку, пов'язану з гігантським розміром зображень. Класифікація цих методів наведена в табл. 1.4.

Таблиця 1.4

Категорії методів цифрової патології, що використовуються для аналізу медичних зображень

Категорія методу	Опис
Статичні	Традиційні методи аналізу нерухомих зображень
Динамічні	Методи, що враховують часові зміни або рух
Роботизовані	Автоматизовані системи збору та обробки зразків
Повнослайдові	Сканування та аналіз цілих гістологічних препаратів з високою роздільною здатністю
Гібридні	Поєднання кількох підходів для підвищення точності

Хоча методи, наведені в табл. 1.4, є точними для гістології, їхнє пряме застосування в радіології є обмеженим. Радіологія оперує 3D/4D об'ємами, де важливою є просторова узгодженість між зрізами та стійкість до фізичних артефактів сканування (наприклад, рух пацієнта, неоднорідність магнітного поля). Табл. 1.4 демонструє підходи до опрацювання великих 2D зображень, проте не відображає нагальну потребу радіології в методах, стійких до варіативності обладнання між різними виробниками сканерів, наприклад, Siemens, GE, Philips тощо. У дисертаційній роботі акцент зроблено на створенні методів для радіологічних даних, які враховують цю гетерогенність.

Стандартні CNN, що навчені без попередньої ініціалізації або адаптовані без урахування специфіки домену, часто ігнорують багатий контекст медичних знань. Це обмежує їхнє впровадження за умов малих вибірок та знижує інтерпретованість рішень. Проблема, яка схематично проілюстрована на рис. 1.4, демонструє необхідність розроблення методів, стійких до варіативності обладнання, що є одним із завдань даної роботи.

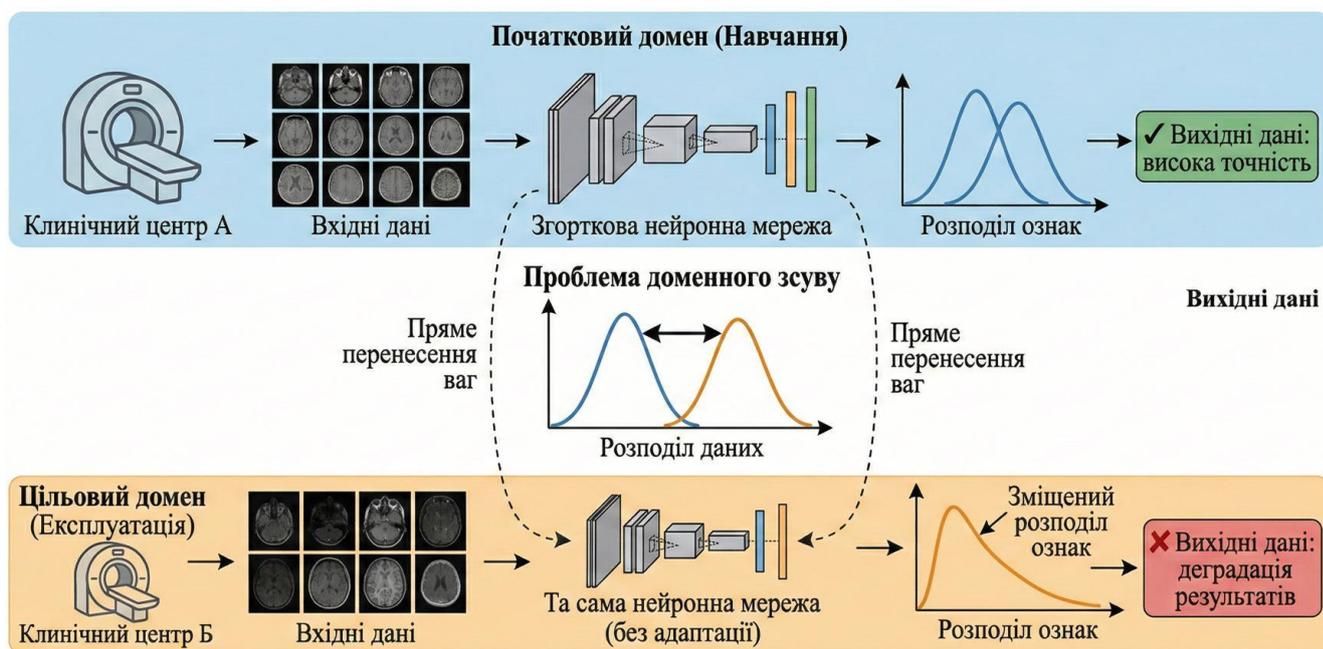


Рисунок 1.4 – Ілюстрація проблеми доменного зсуву в медичному діагностуванні: відмінності в розподілі даних між різними сканерами та клінічними центрами, що призводять до деградації точності моделей

1.2.2 Аналіз підходів до інтеграції знань із медичних наборів даних у моделі глибокого навчання

Інтеграція знань через використання додаткових наборів даних є однією з найбільш розроблених стратегій. Згідно з [98], є дві основні стратегії використання попередньо навчених моделей (див. рис. 1.5).

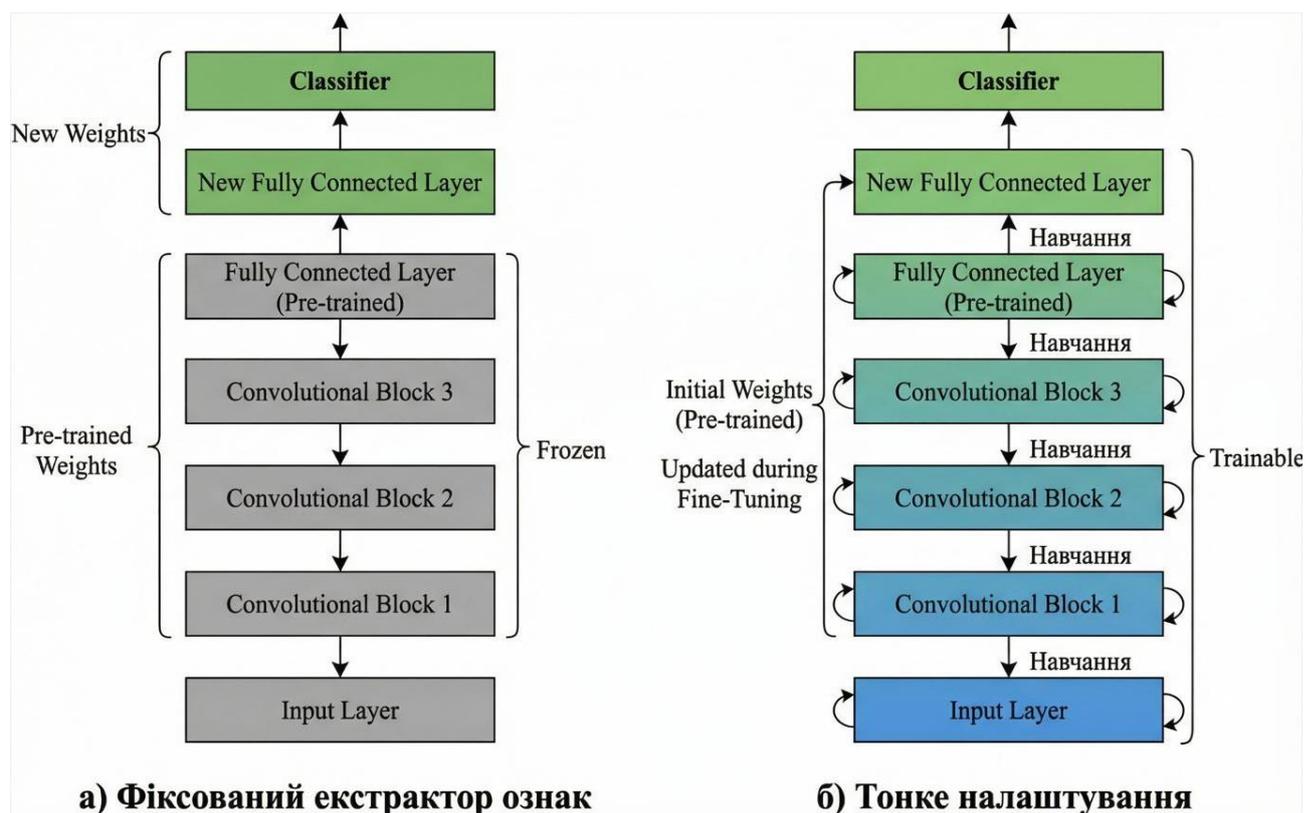


Рисунок 1.5 – Дві стратегії використання попередньо навчених моделей DL для аналізу медичних зображень: а) як фіксований екстрактор ознак та б) як ініціалізація для тонке налаштування на цільовому наборі даних [67]

Перша стратегія (рис. 1.5а) використовує мережу M_{pre} як фіксований екстрактор ознак. Вихідний вектор використовується для навчання класифікатора C . Цей підхід зменшує ризик перенавчання на малих наборах даних, що підтверджено в дослідженнях [38, 99], однак він не дає змогу адаптувати самі ознаки до специфіки нової задачі.

Друга стратегія (рис. 1.5б) передбачає тонке налаштування усієї мережі або її частини. Параметри ініціалізуються значеннями θ_{source} , а потім оновлюються на цільових даних. Цей метод дає змогу адаптувати високорівневі ознаки до специфіки медичних зображень і є стандартом для багатьох задач, включно з дерматоскопією [12] та рентгенографією [39]. Проте, без належної регуляризації, цей підхід схильний до «катастрофічного забування» та втрати узагальнюючої здатності при зміні домену.

Окрім трансферного навчання, важливим механізмом є дистиляція знань. Це дає змогу передавати інформацію від складних ансамблів до компактних моделей або між різними модальностями [100]. Сучасні методи дистиляції включають використання метазнань [101] та адаптацію до нових доменів [102, 103]. Для підвищення надійності сегментації розробляються методи дистиляції форми та інтенсивності [104], а також методи навчання на основі точкових анотацій [105].

Аналіз літератури, зокрема робіт [106–110], показує, що хоча методи трансферного навчання та дистиляції покращують результати, вони здебільшого оперують статистичними розподілами даних. Їм бракує механізму для явної інтеграції структурованих знань (наприклад, «пухлина не може бути всередині кістки») [106, 107]. Наявні методи є «сліпими» до семантики та анатомії [108], покладаючись лише на кореляції пікселів [109]. Це призводить до топологічних помилок у сегментації та логічних суперечностей у класифікації [110]. Саме тому виникає потреба в методах, які мають явно кодувати подібні обмеження в архітектуру нейромережевої моделі.

1.3. Характеристики та формалізація знань предметної області

Процес медичного діагностування не є лінійним перетворенням вхідного сигналу у вихідний діагноз. Він ґрунтується на складній системі знань та евристик. Згідно з класифікацією, наведеною в роботах [11, 14, 67], виділимо категорії знань та розглянемо способи їхньої математичної формалізації.

Навчання лікаря та процес діагностування ґрунтуються на шаблонах, що властиві конкретній галузі медицини. Наприклад, лікарі-радіологи використовують стратегії візуального пошуку, що включають глобальний огляд та детальне сканування зон інтересу.

Знання про зони інтересу формально подамо як мапу пріоритетів $A_{\text{prior}} \in [0,1]^{H \times W}$. Задача інтеграції полягає в мінімізації розбіжності між картою уваги моделі A_{model} та експертною картою:

$$\mathcal{L}_{\text{attn}} = \|A_{\text{model}} - A_{\text{prior}}\|^2. \quad (1.5)$$

У моделі AG-CNN [42] для діагностування глаукоми подібний підхід у формулі (1.5) дав змогу значно підвищити чутливість. Подібні механізми інтегровані в моделі для класифікації [111] та прогнозування [112]. Інший підхід – імітація навчального плану [72], де ваги прикладів у функції втрат $w_i(t)$ змінюються із часом t , від простих до складних: $\mathcal{L} = \sum w_i(t) \mathcal{L}_i$. Це відображає педагогічний процес навчання студентів-медиків.

Архітектури також можуть імітувати процедурні шаблони, наприклад, через багатопотокове опрацювання (глобальний/локальний огляд) [19] або використання симетрії (порівняння лівої та правої легені або молочної залози) [113–115]. Така структура (див. рис. 1.6) дає змогу моделі враховувати як контекст, так і деталі текстури.

Медичне діагностування опирається на стандартизовані системи опису: BI-RADS, АНА segments. Інтеграція цих знань вимагає подолання «семантичного розриву». Знання можуть бути представлені у вигляді графа знань $\mathcal{G} = (V, E)$, де V – медичні поняття, а E – відношення між ними. Векторні представлення вершин графа v_i можуть бути інтегровані з візуальними ознаками CNN.

Для текстових даних (радіологічні звіти) використовуються моделі, як от BERT [116] та BioBERT [117]. Гібридні архітектури, такі як TieNet [118], використовують спільний простір вбудовування. Важливим є також логічне

виведення та узгодженість смислових зв'язків у текстах [34, 119], що дає змогу перевіряти узгодженість діагнозів.

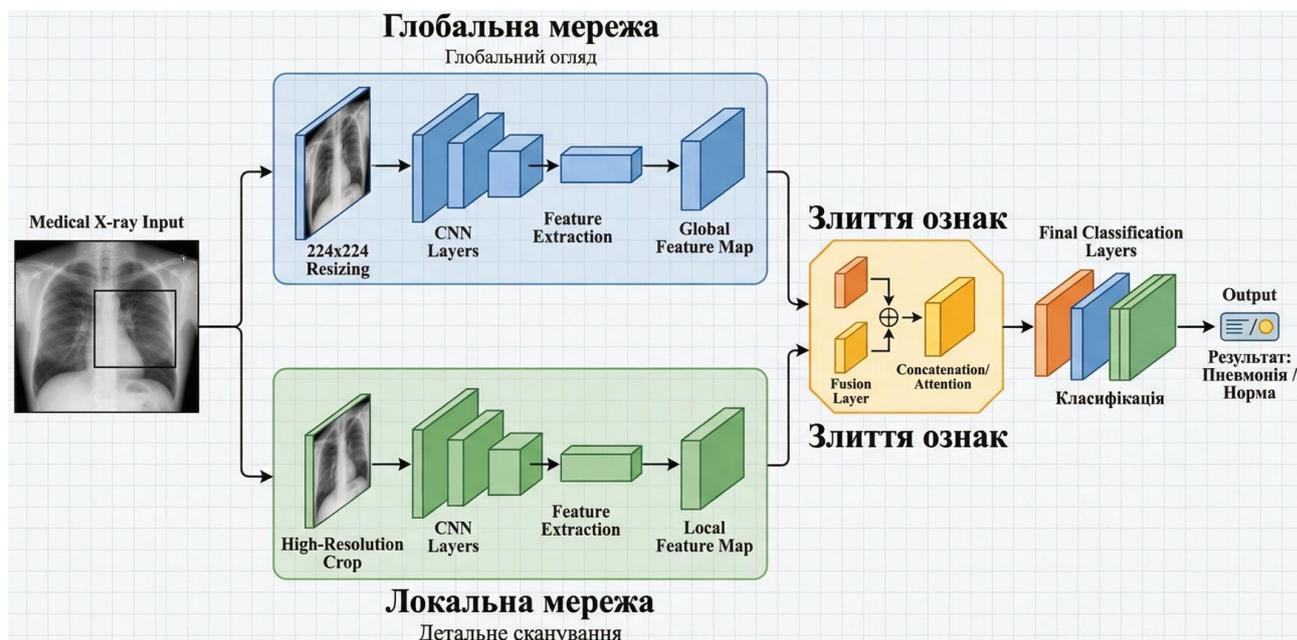


Рисунок 1.6 – Ілюстрація архітектури, що імітує діагностичний шаблон радіолога: глобальна та локальна гілки опрацювання з подальшим злиттям ознак

Однак помітним недоліком більшості наявних мультимодальних систем є слабка зв'язність компонентів: текст і зображення часто обробляються паралельно і зливаються лише на останньому етапі, втрачаючи тонкі кореляції (наприклад, локалізацію описаного в тексті вогнища на зображенні). Крім того, однією з проблем медичного AI, яка часто ігнорується в гонитві за точністю, є відсутність інтерпретованості. Лікарі не можуть довіряти «чорній скриньці», яка видає діагноз без пояснення.

Інтеграція знань є ключем до вирішення цієї проблеми. Графові згорткові мережі (англ. «Graph Convolutional Network», GCN) та механізми уваги дають можливість візуалізувати, які саме анатомічні структури або зв'язки між ними вплинули на рішення. Наприклад, модель може підсвітити не просто серце, а конкретно потовщену міжшлуночкову перегородку, що є ознакою гіпертрофічної кардіоміопатії. Методи, такі як GCNExplainer [120], намагаються пояснити

прогнози графів, але їхня адаптація до медичних зображень залишається відкритою задачею. Відсутність вбудованої інтерпретованості в стандартних CNN є суттєвим обмеженням, яке потребує переходу до архітектур, що орієнтовані на знання.

Методологія інтеграції знань виходить за межі класифікації і є актуальною для задач реконструкції, пошуку та генерації описів. Граф знань (англ. «Knowledge Graph», KG) стає центральним елементом таких систем. Огляд методів побудови пацієнт-орієнтованих графів наведено в дослідженні [121]. Використання GCN, таких як GAT [20], дає змогу обробляти такі структури доволі точно та ефективно. У дослідженнях [122, 123] вектори з графів знань використовуються для покращення діагностування та генерації звітів. Також активно розвиваються методи вбудовування графів [22] та ієрархічного навчання представлень [124]. Для класифікації графів використовуються архітектури DGCNN [21], а для пояснення рішень – методи GCNExplainer [120]. Особливої уваги заслуговують методи напівконтрольованого навчання на графах [125] та використання апріорних знань для класифікації [126].

У задачах реконструкції знання виступають як апріорні обмеження. Використання ГЗМ, таких як DAGAN [95], дає змогу відновити деталі МРТ. Системи пошуку за вмістом використовують семантичне збагачення вектора ознак [127] для знаходження схожих історичних випадків.

Автоматична генерація описів вимагає перетворення візуальних ознак у послідовність слів, де інтеграція знань забезпечує фактологічну точність. Використання механізмів пошуку та перефразування [128], а також гібридних агентів із навчанням із підкріпленням [129], дає змогу генерувати звіти, що відповідають професійному стилю.

Попри різноманіття методів, здебільшого вони фокусуються на одному аспекті даних: або текст, або зображення, або граф. Наразі немає єдиного підходу, який би поєднував низькорівневе опрацювання зображень (сегментацію) з високорівневим семантичним аналізом (класифікацією та описом) у рамках єдиної, топологічно та логічно узгодженої системи.

1.4. Постановка задачі дослідження

У першому розділі проаналізовано еволюцію підходів до створення систем медичного діагностування: від класичних експертних систем до сучасних моделей глибокого навчання. У результаті проведеного аналітичного огляду джерел, встановлено, що методи, які ґрунтуються виключно на даних, досягли межі ефективності в умовах дефіциту анотованих наборів, варіативності діагностичного обладнання та наявності «семантичного розриву». Попри значний прогрес, інтеграція знань у медичний AI залишається відкритою науковою проблемою, що характеризується низкою викликів.

а) Проблеми ідентифікації та формалізації знань. Експертні знання часто є неявними, а лікарі діють інтуїтивно. Автоматичне вилучення знань із текстів є перспективним, але стикається з проблемою неоднозначності. Інструменти, такі як MetaMap [130] та спеціалізовані бібліотеки опрацювання природної мови (англ. «Natural Language Processing», NLP) [131], допомагають структурувати інформацію, проте вони не завжди правильно обробляють заперечення та модальність. Важливу роль відіграє Уніфікована система медичної мови (англ. «Unified Medical Language System», UMLS) [132].

б) Труднощі представлення та методів включення. Є «семантичний розрив» між символічним представленням знань (правила, онтології) та субсимвольним представленням у нейронних мережах (ваги, вектори). Розроблення диференційованих механізмів, що дають можливість транслювати логічні обмеження в градієнти помилок, є нетривіальною задачею. Прикладами спроб є використання знань про структуру при діагностуванні целиакії [133] та застосування класифікаторів для діагностування раку [76].

в) Проблема доменного зсуву та дистиляція знань. Медичні дані є вкрай гетерогенними. Зображення, отримані на різних сканерах, мають різні статистичні розподіли, що призводить до доменного зсуву. Методи адаптації домену [107] та дистиляції знань [16, 60, 67] можуть бути використані для вирішення цієї проблеми. Такі підходи дають змогу зберегти знання у випадку використання

даних різної модальності або під час роботи з обмеженою кількістю даних [102]. Актуальними є дослідження узгодженості семантики при адаптації [134, 135].

г) Проблема інтерпретованості. Як було зазначено вище, відсутність пояснення рішень є бар'єром для впровадження. Гібридні моделі мають видавати точний результат та надавати обґрунтування мовою термінів предметної області.

Наявні підходи до інтеграції знань (трансферне навчання, механізми уваги) є фрагментарними та не забезпечують системного врахування анатомічних, процедурних та онтологічних знань в архітектурі нейронних мереж. Це зумовлює зниження надійності діагностичних рішень, низьку стійкість до збурень та брак інтерпретованості, що є актуальною науково-прикладною задачею. Одним зі шляхів розв'язання цієї задачі є розроблення гібридних архітектур, які поєднують результативність глибокого навчання з формалізованими медичними знаннями.

Метою дослідження є підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах через створення методів та засобів інтеграції експертних знань у моделі штучного інтелекту.

Для досягнення мети сформульовано такі завдання.

1. Провести аналіз сучасного стану методів глибокого навчання та підходів до формалізації медичних знань, виявити наявні обмеження статистичних підходів та визначити перспективи створення гібридних архітектур.

2. Розробити метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня для забезпечення точності процесу діагностування в умовах зсуву домену та обмеженої розмітки даних.

3. Розробити метод встановлення смислових зв'язків у медичних текстах через інтеграцію онтологічних знань та аналізу тональності в архітектуру нейронної мережі для підвищення точності інтерпретації клінічних записів.

4. Розробити метод сегментації зображень магнітно-резонансної томографії серця, що ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги та спеціалізованої функції втрат із топологічними обмеженнями для забезпечення анатомічної коректності результатів.

5. Розробити метод ідентифікації патологій із використанням графової згорткової мережі, який інтегрує реляційні діагностичні знання та дає змогу моделювати взаємозв'язки між анатомічними структурами.

6. Спроекувати архітектуру інтелектуальної інформаційної системи інтеграції знань, яка забезпечує гнучке оброблення гетерогенних медичних даних та підтримку модульної взаємодії між компонентами сегментації, класифікації та аналізу текстів.

7. Виконати програмну реалізацію інтелектуальної інформаційної системи інтеграції знань на основі спроектованої архітектури, здійснити постановку експерименту та провести комплексні експериментальні дослідження для підтвердження підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах на еталонних медичних наборах даних.

1.5. Висновки до розділу 1

За результатами аналізу сучасного стану технологій комп'ютерного медичного діагностування встановлено, що класичні методи глибокого навчання, які ґрунтуються виключно на статистичному опрацюванні даних, вичерпують свій потенціал. Це зумовлено дефіцитом анотованих наборів даних та високою варіативністю медичного обладнання. Систематичний огляд публікацій підтвердив наявність проблем, поміж яких доменний зсув та семантичний розрив, що обмежують надійність та можливість інтерпретації автоматизованих діагностичних рішень. З'ясовано, що поточні підходи до інтеграції знань є переважно фрагментарними та не забезпечують системного включення експертного досвіду безпосередньо в архітектуру нейронних мереж.

У першому розділі науково обґрунтовано, що перспективним напрямом підвищення точності систем підтримки прийняття рішень є перехід до створення гібридних архітектур. Такі системи здатні синергетично поєднувати обчислювальну результативність методів глибокого навчання з формалізованими медичними знаннями. Здійснено аналіз типів експертних знань, що охоплює

анатомічні, процедурні та онтологічні категорії. Крім того, досліджено алгоритмічні методи їхнього впровадження в нейромережеві моделі, зокрема використання механізмів уваги, підходів на основі дистиляції знань та застосування графових структур для моделювання зв'язків.

На основі цього виконано формальну постановку задачі дослідження та визначено перелік завдань, метою яких є розроблення нових методів інтеграції знань та проєктування архітектури інтелектуальної інформаційної системи. Сформульовано критерії до перспективних діагностичних моделей. Вони мають гарантувати стійкість до збурень через використання адаптивної дистиляції, забезпечувати анатомічну коректність під час сегментації зображень, а також підтримувати механізми реляційного міркування на етапі класифікації патологій. Додатково передбачено необхідність забезпечення логічної узгодженості під час аналізу неструктурованих медичних текстів. Ці вимоги стали методологічним підґрунтям для подальших розробок у роботі.

Основні результати розділу опубліковані у працях [24].

РОЗДІЛ 2.

МОДЕЛІ ТА МЕТОДИ ПЕРЕДАЧІ ЕКСПЕРТНИХ ЗНАНЬ ДО СИСТЕМИ ШТУЧНОГО ІНТЕЛЕКТУ МЕДИЧНОГО ДІАГНОСТИЧНОГО КОМПЛЕКСУ

2.1. Метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня

Розв'язання задачі класифікації медичних зображень в умовах реальної клінічної практики стикається з фундаментальною проблемою гетерогенності даних. Зображення, отримані з різних джерел (сканерів різних виробників, протоколів сканування, демографічних груп пацієнтів), мають відмінні статистичні характеристики, що призводить до явища доменного зсуву. У такому контексті модель, оптимізована на одному розподілі даних (первинний домен), демонструє значне зниження точності та надійності при застосуванні до іншого, хоча й семантично пов'язаного розподілу (цільовий домен).

Класичні методи трансферного навчання лише частково вирішують цю проблему, оскільки вони часто вимагають значних обсягів розмічених даних у цільовому домені для тонкого налаштування, що в медицині є дефіцитним ресурсом. Альтернативним підходом є використання ансамблевих методів, проте вони є надмірно громіздкими для використання в системах реального часу та на периферійних пристроях.

Для усунення цієї суперечності в дисертаційній роботі пропонується удосконалений метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня (англ. «Enhanced Multi-Teachers Knowledge Distillation», EMTKD). Описаний нижче метод ґрунтується на парадигмі «вчитель-учень» і передбачає трансфер узагальненої інформації від колективу спеціалізованих моделей-вчителів до єдиної компактної моделі-учня.

2.1.1 Математична формалізація задачі адаптації домену в умовах гетерогенності медичних даних

Для побудови коректної математичної моделі процесу дистиляції необхідно ввести формальний опис просторів даних, що враховує їхню розподілену природу. Припустимо наявність множини з n початкових доменів, кожен із яких представлений відповідним набором даних, на якому проведено навчання окремої моделі-вчителя.

Формалізуємо n наборів даних медичних зображень у такий спосіб:

$$D_j^t = \left\{ (x_i^j, y_i^j) \right\}_{i=1}^{N_j}, \quad j = 1, \dots, n, \quad (2.1)$$

де x_i^j належить до простору ознак \mathcal{X}_j та відображає i -е вхідне зображення з j -го набору даних, y_i^j належить до простору міток \mathcal{Y}_j і є відповідною діагностичною міткою, N_j позначає кількість зразків у вибірці j .

Кожен набір даних D_j^t характеризується власним маргінальним розподілом ймовірностей $P_j(X)$, що відображає специфіку конкретного джерела даних (наприклад, фізичні характеристики сенсора МРТ чи КТ).

Цільовий домен, для якого розробляється модель-учень f_θ , поданий набором даних D_S , який структурно поділяється на дві підмножини, що не перетинаються, для забезпечення можливості напівконтрольованого навчання:

$$D_S = \{D_{S'}, D_{S''}\}, \quad (2.2)$$

де $D_{S'}$ – це невелика за обсягом анотована частина вибірки, яка використовується для налаштування та валідації механізмів фільтрації, а $D_{S''}$ – масивна неанотована частина, що використовується для дистиляції знань та навчання без вчителя.

Анотована підмножина визначається як:

$$D_{S'} = \{(x_{i'}, y_{i'})\}_{i=1}^{N'}, \quad x_{i'} \in \mathcal{X}_S, \quad y_{i'} \in \mathcal{Y}_S, \quad (2.3)$$

Неанотовану підмножину визначено у такий спосіб:

$$D_{S''} = \{x_{i''}\}_{i=1}^{N''}, \quad x_{i''} \in \mathcal{X}_S, \quad (2.4)$$

Водночас виконується умова $N' \ll N''$, що є типовим для задач медичного діагностування, де отримання експертної розмітки є вартісним та тривалим процесом.

Задача дослідження полягає в знаходженні параметрів θ моделі-учня f_θ , яка мінімізує очікуваний ризик на цільовому домені D_S , використовуючи «приховані знання», вилучені зі множини моделей-вчителів $\{T_1, \dots, T_n\}$, попередньо навчених на D_j' , за умови жорстких обмежень на обчислювальні ресурси під час виведення результатів за практичних умов експлуатації або інференсу (англ. «inference»).

2.1.2 Структурна організація та алгоритмічна реалізація методу адаптивної дистиляції знань

Загальна архітектура удосконаленого ЕМТКД ґрунтується на ієрархічній схемі передачі інформації. На відміну від побудови класичних ансамблів, де результати просто усереднюються, запропонований підхід реалізує інтелектуальне об'єднання (або злиття) ознак, що дає змогу враховувати компетентність кожного вчителя щодо конкретного вхідного зразка. Схематичне зображення підходу представлено на рис. 2.1.

Метод реалізовано через послідовне виконання трьох блоків:

- блок 1 – формування експертних знань: незалежне навчання моделей-вчителів та моделі адаптації домену для вилучення інваріантних ознак;
- блок 2 – адаптивна дистиляція: вилучення, фільтрація та нелінійне злиття ознак для формування узагальненого вектора знань;

– блок 3 – навчання студента: оптимізація цільової моделі з використанням псевдоміток та збереженням приватності даних.

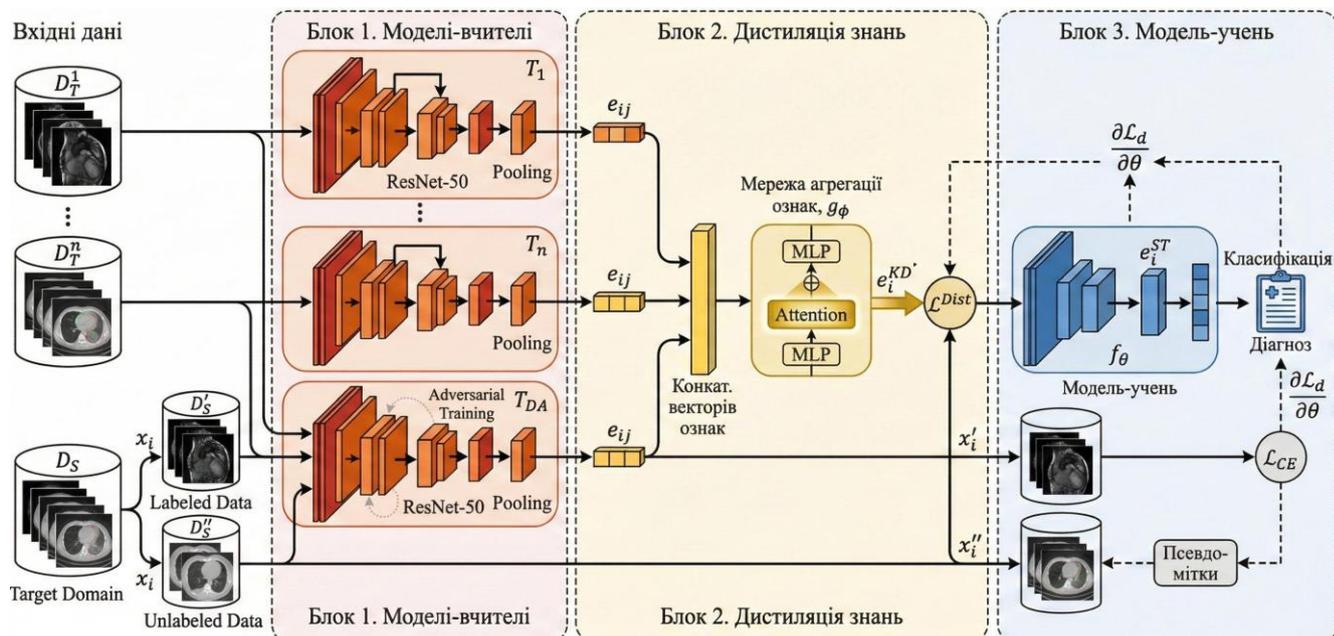


Рисунок 2.1 – Схематичне подання удосконаленого ЕМТКД; блок 1 включає навчання моделей-вчителів з адаптацією домену; блок 2 виконує адаптивну дистиліацію; блок 3 навчає учня з використанням напівкерованого навчання

На першому етапі відбувається навчання ансамблю вчителів. Кожен вчитель T_j оптимізується для мінімізації емпіричного ризику (перехресної ентропії \mathcal{L}_{CE}) на своєму специфічному домені:

$$\theta_j = \arg \min_{\theta_j} \left\{ \sum_{(x_i^j, y_i^j) \in D_j^i} \mathcal{L}_{CE} (T_j (x_i^j; \theta_j), y_i^j) \right\}. \quad (2.5)$$

Важливим елементом запропонованого методу є введення додаткової моделі-вчителя T_{DA} , призначеної для змагальної адаптації домену. Ця модель навчається на об'єднаній вибірці всіх вхідних даних із використанням підходу Domain-Adversarial Neural Network (DANN). Метою T_{DA} є формування простору ознак, у якому мінімізується розбіжність між розподілами різних доменів, що дає змогу

виділяти універсальні діагностичні шаблони, інваріантні до технічних умов отримання зображень (див. рис. 2.2).

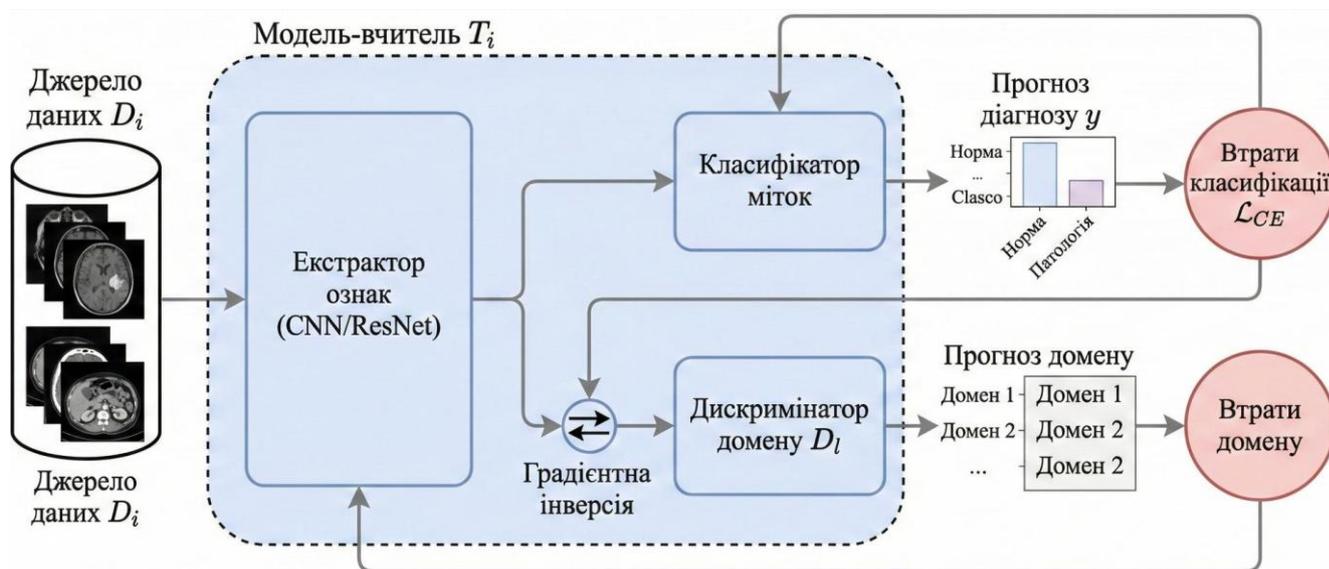


Рисунок 2.2 – Схема блоку 1: навчання моделей-вчителів з інтегрованою адаптацією домену; кожен вчитель T_i навчається на джерелі даних D_i , одночасно змагаючись із дискримінатором домену D_l для вивчення інваріантних ознак

На другому етапі реалізується механізм дистилляції. Навчені моделі-вчителі функціонують як генератори глибоких ознак з фіксованими параметрами. Для кожного вхідного зразка z_i із цільового домену D_S формується набір векторних представлень у такий спосіб:

$$T_j : z_i \rightarrow e_{ij}, \quad \text{де } z_i \in D_S, \quad i \in \{1, \dots, N' + N''\}, \quad j = 1, \dots, n. \quad (2.6)$$

Тут виникає важливе питання об'єднання: як система розуміє, чий внесок важливіший, і що робити, якщо вчитель помиляється? Просте усереднення векторів є вразливим до помилок окремих моделей, особливо в умовах сильного доменного зсуву. У відповідь на цю складність в межах ЕМТКД розроблено механізм селективної фільтрації.

Якщо вхідний зразок z_i належить до неанотованої множини $D_{S''}$, формується розширений вектор ознак через просту конкатенацію виходів усіх вчителів та моделі адаптації домену:

$$E_i = \text{concat}(e_{i1}, e_{i2}, \dots, e_{in}, e_{i,DA}). \quad (2.7)$$

У випадку, коли зразок z_i належить до анотованої множини $D_{S'}$, застосовується процедура інтелектуальної фільтрації. Вводиться індикаторна функція m_{ij} (фільтр), яка оцінює коректність передбачення j -го вчителя щодо істинної мітки $y_{i'}$:

$$m_{ij} = \mathbb{I}(\arg \max \{T_j(z_i; \theta_j)\} = y_{i'}), \quad \text{для } z_i = (x_i, y_{i'}) \in D_{S'}. \quad (2.8)$$

Ця функція дає змогу динамічно виключити вплив тих моделей-вчителів, які помиляються на конкретних прикладах цільового домену, запобігаючи поширенню неправдивих знань. Агрегований вектор для анотованих даних формується з урахуванням маски:

$$E_{i'} = \text{concat}(m_{i1}e_{i1}, \dots, m_{in}e_{in}, e_{i,DA}). \quad (2.9)$$

Сформовані вектори E_i та $E_{i'}$ подаються на вхід агрегаційної нейронної мережі g_ϕ (див. рис. 2.3), яка виконує нелінійне перетворення та злиття різнорідних ознак у єдиний компактний вектор знань e_i^{KD} . Агрегаційна мережа реалізується як багатошаровий перцептрон (БШП), що дає змогу моделювати складні нелінійні залежності між ознаками різних вчителів:

$$g_\phi : \begin{cases} E_i \rightarrow e_i^{\text{KD}}, & \text{якщо } z_i \in D_{S''}; \\ E_{i'} \rightarrow e_i^{\text{KD}}, & \text{якщо } z_i \in D_{S'}, \end{cases} \quad (2.10)$$

де вихідний вектор обчислюється через послідовність лінійних шарів та функцій активації ReLU:

$$e_i^{\text{KD}} = \text{ReLU}(\mathbf{W}_2 \cdot \text{ReLU}(\mathbf{W}_1 \cdot E_{\text{input}} + b_1) + b_2). \quad (2.11)$$

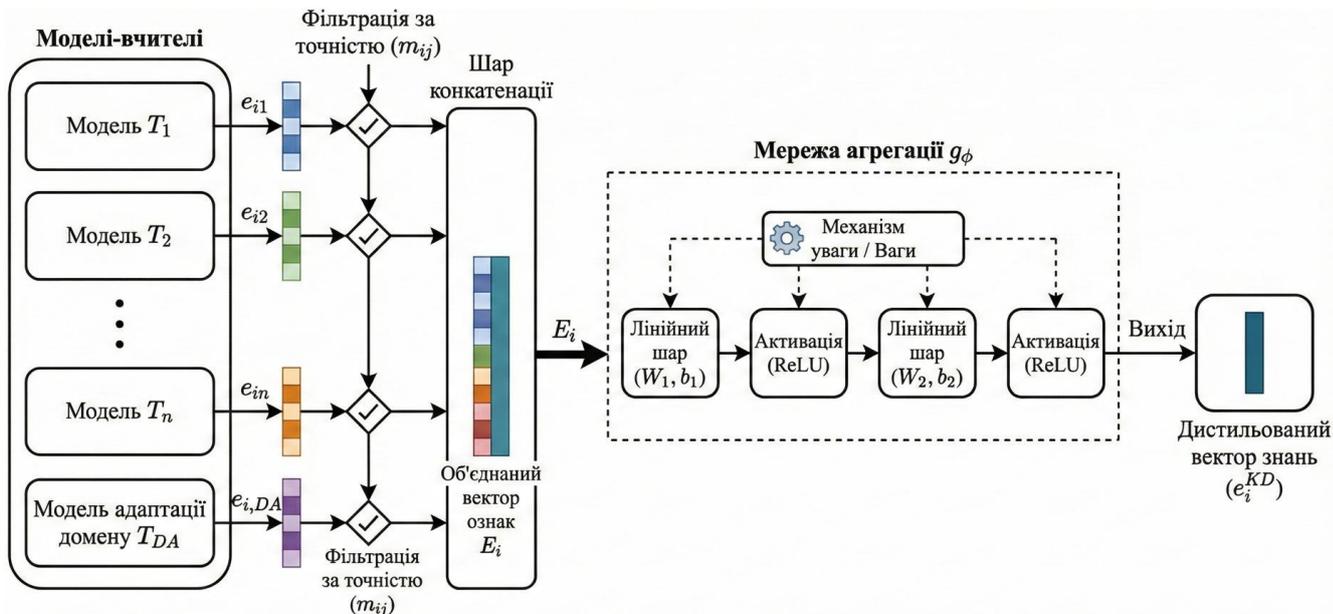


Рисунок 2.3 – Детальна схема блоку 2 з адаптивною дистилляцією знань, що відображає процес конкатенації векторів ознак, проходження через мережу агрегації, застосування механізму уваги та формування дистильованого вектора

На третьому етапі відбувається навчання моделі-учня f_θ (див. рис. 2.4), яка повинна відтворити отриманий узагальнений вектор знань. Модель-учень генерує власний вектор ознак e_i^{ST} :

$$f_\theta : z_i \rightarrow e_i^{ST}, \quad z_i \in D_S. \quad (2.12)$$

Процес навчання ґрунтується на мінімізації функції втрат дистилляції, яка визначається як метрика відстані (наприклад, середньоквадратична помилка) між вектором знань вчителя та вектором моделі-учня:

$$\mathcal{L}_i^{\text{Dist}} = \|e_i^{KD} - e_i^{ST}\|_2^2 = \left\| g_\phi \left(\text{AggFeatures}(z_i, \{T_j\}, F) \right) - f_\theta(z_i) \right\|_2^2. \quad (2.13)$$

Для забезпечення стабільності градієнтного спуску оптимізація проводиться пакетним методом, де функція втрат усереднюється по пакету розміром B :

$$\mathcal{L}_B^{\text{Dist}} = \frac{1}{B} \sum_{k=1}^B \mathcal{L}_{z_k}^{\text{Dist}}(e_{z_k}^{KD}, e_{z_k}^{ST}). \quad (2.14)$$

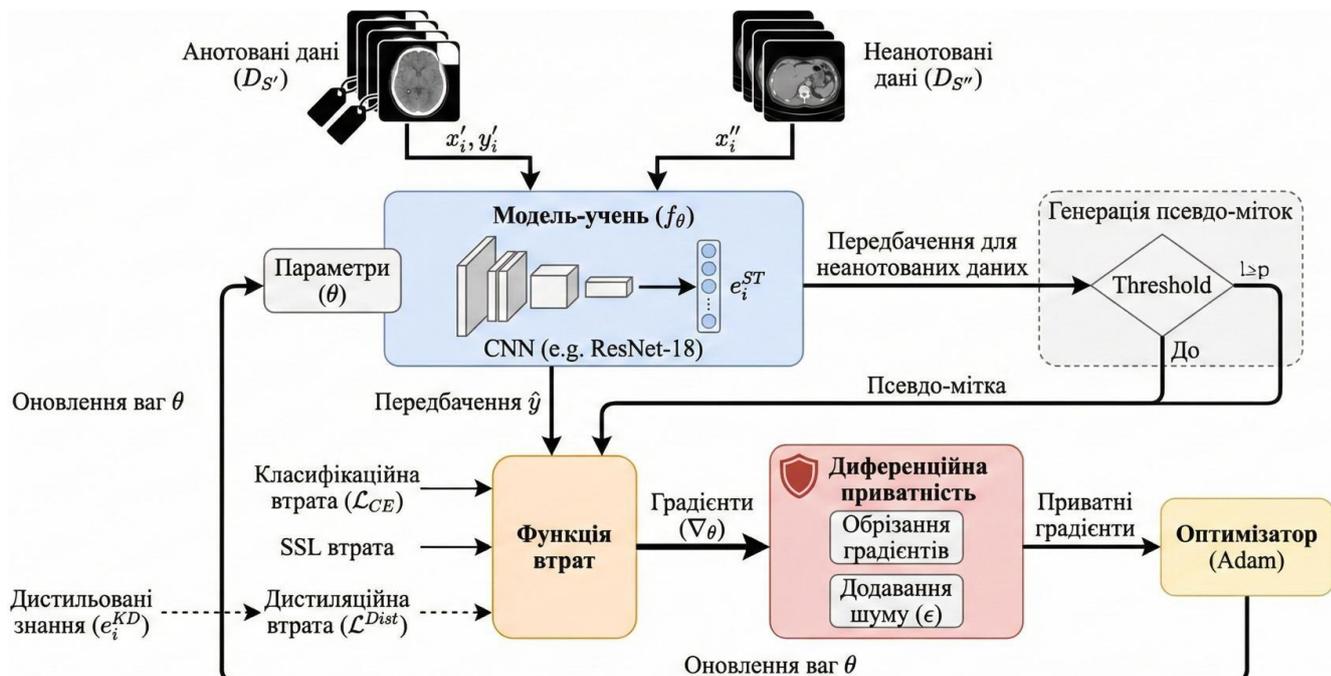


Рисунок 2.4 – Схема блоку 3 з навчанням моделі-учня та механізмів збереження приватності; використовуються псевдомітки для неанотованих даних та диференційна приватність при оновленні градієнтів

Оновлення параметрів моделі-учня θ здійснюється за допомогою адаптивного алгоритму оптимізації Adam, який враховує моменти градієнтів першого та другого порядку для прискорення збіжності:

$$\theta_{t+1} = \theta_t - \eta \frac{m_t}{\sqrt{v_t + \epsilon}} \nabla_{\theta} \mathcal{L}_B^{\text{Dist}}(\theta_t), \quad (2.15)$$

де η – швидкість навчання, m_t та v_t – експоненційні ковзні середні градієнта та його квадрата.

Паралельно з дистилляцією протягом кожної епохи відбувається донавчання класифікатора f_c та коригування агрегатора g_{ϕ} на доступних анотованих даних D_{S^a} з використанням функції втрат перехресної ентропії:

$$\mathcal{L}_{CE}(y', \hat{y}') = -\frac{1}{N'} \sum_{i=1}^{N'} \left(y_i' \cdot \log(y_i'(x_i)) + (1 - y_i') \cdot \log(1 - y_i'(x_i)) \right), \quad (2.16)$$

де y_i – ймовірність приналежності до позитивного класу, отримана після застосування сигмоїдної активації до виходу класифікатора.

Це дає змогу спрямувати процес формування ознак у бік максимальної дискримінативності для конкретної діагностичної задачі. Оновлення всіх параметрів системи на цьому етапі відбувається спільно:

$$(\phi, \theta, \theta_c) \leftarrow \text{Adam}(\mathcal{L}_{CE}(y', \hat{y}'), (\phi, \theta, \theta_c)). \quad (2.17)$$

Завершальним етапом є тонке налаштування моделі-учня, яке виконується з меншою швидкістю навчання для досягнення локального мінімуму функції втрат на цільовому домені:

$$(\theta', \theta_c) \leftarrow \text{Adam}(\mathcal{L}_{CE}(y', \hat{y}'), (\theta, \theta_c)). \quad (2.18)$$

Деталізована покрокова схема процесу дистиляції та навчання моделі-учня наведена на рис. 2.5.

Далі подамо виконання ЕМТКД покроково.

Вхідними даними методу є 1) множина наборів даних початкових доменів $\{D_j^t\}_{j=1}^n$; 2) анотована $D_{S'}$ та неанотована $D_{S''}$ вибірки цільового домену; 3) попередньо визначені архітектури для вчителів T_j та учня f_θ .

Крок 1. Підготовка вчителів:

- 1) навчити n моделей-вчителів T_j на відповідних наборах D_j^t до досягнення критерію збіжності;
- 2) навчити модель адаптації домену T_{DA} на об'єднаній вибірці всіх доменів;
- 3) заморозити вагові коефіцієнти всіх моделей-вчителів для запобігання їхній зміні на наступних етапах.

Крок 2. Агрегація та дистиляція:

- 1) для кожного мініпаketу B із цільового домену D_S :

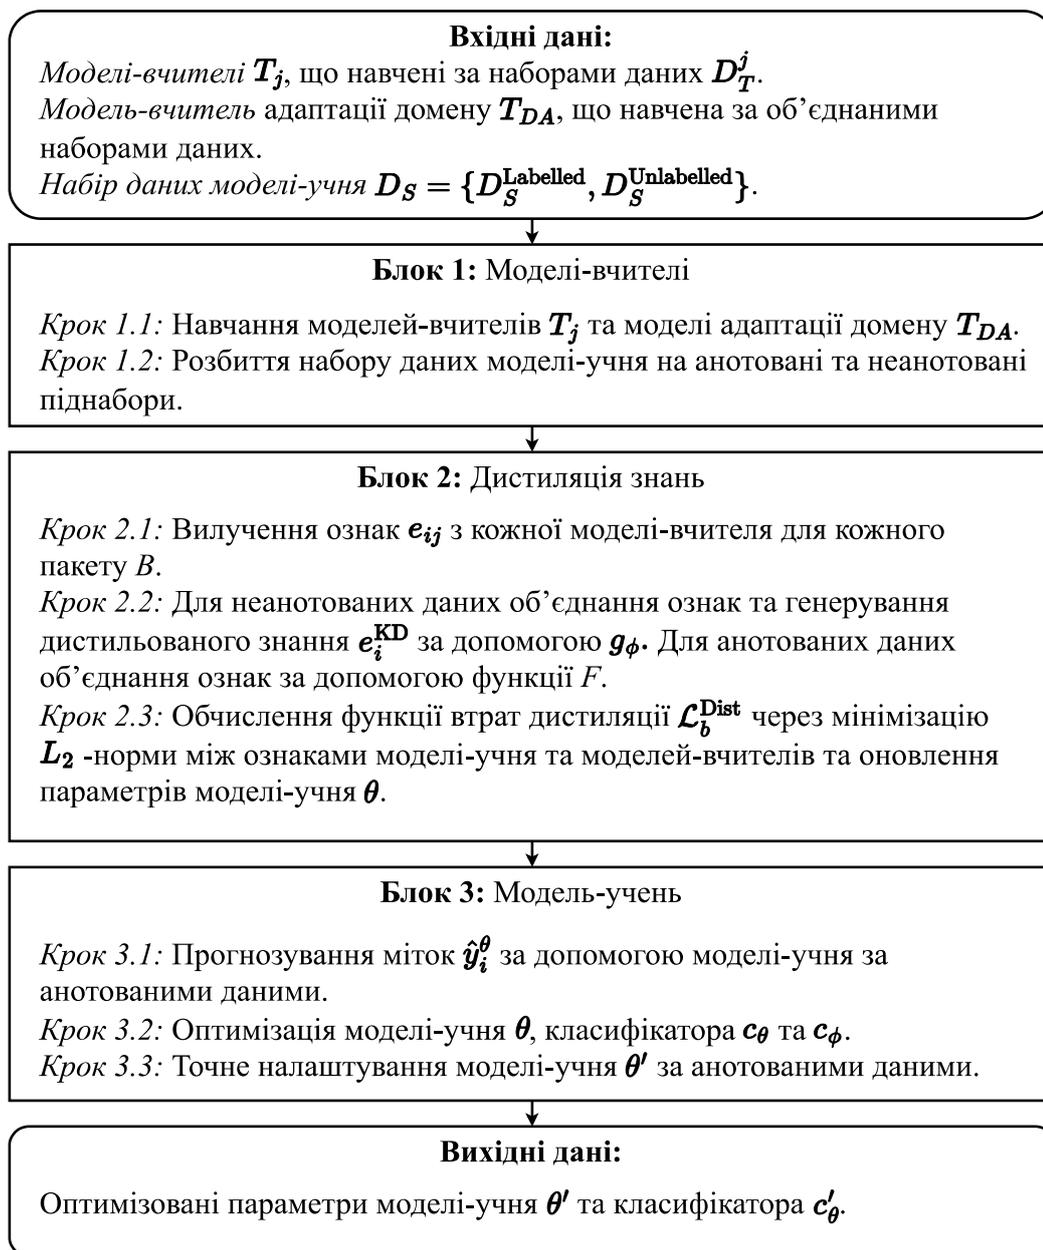


Рисунок 2.5 – Покрокова схема методу адаптивної дистиляції знань, що ілюструє потік даних від вхідних моделей-вчителів через блоки вилучення ознак, їхнього зважування та агрегації до фінального оновлення параметрів моделі-учня

- виконати пряме поширення зображень через усі моделі T_j та T_{DA} для отримання векторів ознак e_{ij} ;
- для анотованих даних ($D_{S'}$): обчислити маску валідності m_{ij} за формулою (2.8);
- сконкатенувати вектори ознак відповідно до формул (2.7) або (2.9);

– обробити об'єднаний вектор мережею-агрегатором g_ϕ для отримання цільового вектора знань e_i^{KD} ;

2) виконати пряме поширення зображень через модель-учня f_θ для отримання поточного вектора ознак e_i^{ST} ;

3) обчислити значення функції втрат дистиляції $\mathcal{L}^{\text{Dist}}$, згідно з (2.13);

4) виконати оновлення параметрів учня θ та агрегатора ϕ методом зворотного поширення похибки.

Крок 3. Тонке налаштування: донавчити класифікатор моделі-учня на анотованій вибірці D_S , з використанням функції втрат \mathcal{L}_{CE} .

Вихідними даними методу є оптимізована компактна модель-учень f_θ , що готова до розгортання в медичній інформаційній системі.

2.1.3 Аналіз обчислювальної складності навчання та оцінювання апаратних вимог для впровадження системи

Впровадження ансамблевих методів та складних механізмів адаптації неминуче актуалізує питання ресурсомісткості запропонованого рішення. Для розуміння практичної значущості удосконаленого ЕМТКД варто розмежувати дві фази життєвого циклу моделі: етапу навчання та етапу інференсу.

Процес навчання моделі-учня за удосконаленим ЕМТКД є ресурсомістким. Використання динамічного ансамблю з $n + 1$ глибоких мереж (де n – кількість доменних вчителів, плюс модель адаптації домену) вимагає значних обчислювальних потужностей. Якщо позначити C_T як обчислювальну складність прямого проходу однієї моделі-вчителя, а C_S – складність моделі-учня, то загальна складність однієї ітерації навчання наближено становить:

$$O_{\text{train}} \approx O((n + 1) \cdot C_T + C_S + C_{\text{agg}}),$$

де C_{agg} – складність мережі агрегації (БШП), яка є незначною проти глибоких згорткових мереж C_T .

Експериментальні дослідження показали, що навчання моделі-учня за удосконаленим ЕМТКД на сучасних графічних прискорювачах може займати до 12 годин для повного циклу на великих наборах даних, що суттєво перевищує час навчання базових моделей (див. табл. 2.1). Загальна кількість параметрів, що утримуються в пам'яті під час навчання, може сягати 70 млн і більше (залежно від архітектури вчителів, наприклад, ResNet-50). Це робить процес навчання моделі неможливим безпосередньо на периферійних пристроях або в умовах обмежених ресурсів локальних серверів лікарень.

Таблиця 2.1

Час навчання та складність моделей для різних методів адаптації домену

Модель	Час навчання (год.) ↓	Параметри під час навчання (млн.) ↓
STM (baseline)	5	25
DANN [65]	6	30
MTKD [138]	7	60
MTMS [101]	9	65
EMTKD (запроп.)	12	70

Однак, варто підкреслити, що етап навчання є одноразовою процедурою, яка виконується централізовано на високопродуктивних серверах або в хмарному середовищі. Високі витрати часу та енергії на цьому етапі є стратегічною інвестицією у якість та надійність кінцевої моделі.

Складність на етапі інференсу. Результатом роботи методу є відокремлена компактна модель-учень архітектури ResNet-18, яка повністю відв'язана від ансамблю вчителів після завершення навчання. Складність інференсу визначено виключно складністю архітектури учня у такий спосіб:

$$O_{inference} = O(C_S). \quad (2.19)$$

Формула (2.19) передбачає, що на етапі інференсу в реальних клінічних умовах система не потребує наявності вчителів чи потужних GPU-кластерів. Апаратні вимоги до інференсу є мінімальними, що дає змогу розгортати отриману модель на периферійних пристроях, планшетах або вбудованих системах медичного обладнання без втрати точності.

Результати тестування пропускної здатності моделі-учня при використанні різних провайдерів виконання ONNX (табл. 2.2) демонструють, що отримана модель здатна обробляти зображення за 0,8–1,2 секунди навіть на менш потужному обладнанні, що повністю задовольняє вимоги до діагностичних комплексів.

Таблиця 2.2

Пропускна здатність інференсу та використання ресурсів провайдерами виконання ONNX

Провайдер (EP)	Медіана (с) ↓	P95 (с) ↓	Пам'ять (ГБ) ↓
CPU	5,3	6,6	3,2
CUDA	0,8	1,1	4,1
DirectML	1,2	1,6	3,8

У табл. 2.3 наведено приклад рекомендованої конфігурації гіперпараметрів та розмірностей шарів, що можуть бути використані при реалізації запропонованого методу, що дає можливість забезпечити баланс між швидкістю збіжності та якістю навчання.

Для кращого розуміння контексту дистиляції в межах удосконаленого ЕМТКД, розглянемо порівняння наявних підходів у табл. 2.4, що демонструє переваги запропонованого методу. Хоча ЕМТКД має вищу складність на етапі навчання, він позбавлений недоліків простих методів дистиляції, як от вразливість до помилок вчителя, та методів простого усереднення, наприклад, неадаптивність до доменних зсувів.

Таблиця 2.3

Рекомендована конфігурація параметрів та розмірностей для реалізації методу адаптивної дистиляції знань

Параметр	Значення / Опис
Кількість моделей-вчителів, $n + 1$	4 (3 доменно-специфічні + 1 T_{DA})
Архітектура вчителів, T_j, T_{DA}	ResNet-50 (попередньо навчена на ImageNet)
Розмірність ознак вчителів, d_j, d_{DA}	2048
Архітектура агрегатора, g_ϕ	MLP: вхід $4 \times 2048 \rightarrow 1024 \rightarrow 2048$
Розмірність e_i^{KD}, d_{KD}	2048
Архітектура моделі-учня, f_θ	ResNet-18 (компактна модель)
Розмірність ознак моделі-учня, d_{ST}	2048
Розмір пакету B (дистиляція)	64
Розмір пакету B_{CE} (оновлення)	32 (з $D_{S'}$)
Кількість епох дистиляції	50
Кількість епох тонкого налаштування	10
Оптимізатор	Adam, $\beta_1 = 0,9, \beta_2 = 0,999$
Швидкість навчання (дистиляція)	1×10^{-4}
Швидкість навчання (тонке налаштування)	1×10^{-6}

Отже, підвищена обчислювальна складність навчання моделі-учня за удосконаленим ЕМТКД є обґрунтованою платою за створення високоточного та надійного до шумів інструменту, який на етапі інференсу є малоресурсним та придатним для використання в реальних умовах українських лікарень з обмеженим ресурсним забезпеченням.

Реалізація запропонованого методу дає змогу створити надійну систему діагностування, яка поєднує в собі переваги використання великих обсягів різномірних даних для навчання та адаптивність до специфічних умов інференсу.

Таблиця 2.4

Порівняння підходів до дистиляції знань у медичній візуалізації

Метод	Основний принцип	Недоліки
Звичайна дистиляція (KD)	Передача знань від одного вчителя до учня через згладжені мітки	Не враховує різноманітність даних з різних доменів; вразлива до помилок вчителя
Багатовчителєва дистиляція (MTKD)	Усереднення прогнозів від кількох вчителів	Конфлікт знань при доменних зсувах; неадаптивне зважування
Адаптивна дистиляція (AEKD)	Динамічне зважування вчителів на основі впевненості	Не використовує доменну адаптацію для вирівнювання ознак
EMTKD (запроп.)	Поєднання адаптивного зважування, доменної адаптації та напівкерowanego навчання	Підвищена обчислювальна складність на етапі навчання

Метод забезпечує подолання проблеми доменного зсуву, покращує використання обчислювальних ресурсів на етапі впровадження та гарантує конфіденційність даних пацієнтів (оскільки для навчання моделі-учня в новому центрі не потрібно фізично передавати необроблені дані з інших лікарень, достатньо використовувати попередньо навчені моделі-вчителі), що робить його перспективним інструментом для побудови сучасних медичних діагностичних комплексів.

2.2. Метод встановлення смислових зв'язків у медичних текстах через інтеграцію знань предметної області та аналізу клінічної полярності

Галузь NLP у медичному домені стикається з комплексом унікальних викликів, які суттєво відрізняють її від задач загального призначення. Ці виклики зумовлені високою щільністю вузькоспеціалізованої термінології, складністю

синтаксичних конструкцій клінічних записів, наявністю численних абревіатур, що залежать від контексту, та необхідністю точної інтерпретації модальності діагностичних тверджень. Нещодавні досягнення в галузі контекстуальних векторних представлень слів, зокрема поява моделей родини BERT та спеціалізованих архітектур, як от BioELMo, дали змогу суттєво підвищити якість аналізу текстів завдяки здатності моделювати полісемію та синтаксичні залежності.

Проте задача встановлення смислових зв'язків (англ. «Natural Language Inference», NLI) у медичних текстах, яка полягає у визначенні логічного відношення між двома твердженнями – засновком (англ. «premise») та гіпотезою (англ. «hypothesis»), залишається складною для вирішення суто статистичними методами глибокого навчання. Основна проблема полягає в наявності так званого «семантичного розриву»: нейронні мережі оперують статистичними кореляціями між токенами, тоді як лікар-експерт під час прийняття рішень використовує глибокі онтологічні знання (наприклад, розуміння того, що «Лазикс» є гіпонімом поняття «діуретик») та правила клінічної логіки.

У цьому підрозділі наведено опис удосконаленого методу встановлення смислових зв'язків у медичних текстах (англ. «Ontology-augmented Polarity & Negation-aware natural language Inference», OPNI), що призначений для вирішення зазначеної вище проблеми через створення гібридної нейромережевої архітектури. Запропонований підхід поєднує нейромережеві моделі глибокого навчання з формалізованими знаннями предметної області та спеціалізованим алгоритмічним аналізом модальності висловлювань (заперечень та стверджень).

2.2.1 Формалізація задачі та обґрунтування вибору компонентів

Нехай задано вхідну пару текстових послідовностей $X = (P, H)$, де $P = (w_1^P, \dots, w_m^P)$ – засновок (наприклад, фрагмент історії хвороби або опис симптомів пацієнта), а $H = (w_1^H, \dots, w_n^H)$ – гіпотеза (наприклад, твердження про діагноз або призначене лікування). Задача NLI полягає в побудові відображення

$f : (P, H) \rightarrow Y$, де цільовий простір класів $Y \in \{\text{Entailment, Contradiction, Neutral}\}$ позначає «Логічне слідування», «Суперечність» та «Невизначеність», відповідно.

Сучасний розвиток генеративних великих мовних моделей (англ. «Large Language Model», LLM), таких як GPT-4 або Med-PaLM, демонструє вражаючі результати в завданнях розуміння тексту. Проте, у межах дослідження свідомо не використовуються генеративні трансформери; натомість було обрано спеціалізовані гібридні архітектури (BioELMo + BiLSTM + Knowledge Graph).

1. Проблема галюцинацій та верифікованість. Генеративні моделі схильні до конфабуляцій (галюцинацій), що є категорично неприпустимим у клінічній практиці. Запропонована архітектура є детермінованою: процес прийняття рішення ґрунтується на чіткій матриці уваги та верифікованих зв'язках із графа знань. Це дає змогу уникнути ефекту «чорної скриньки» та забезпечити прозорість висновків.

2. Ресурсомісткість та приватність. Використання LLM вимагає значних обчислювальних потужностей або передачі даних у хмару, що створює ризики порушення конфіденційності пацієнтів (відповідно до норм GDPR/НІРАА). Розроблена модель є компактною і здатна працювати локально на серверах лікувального закладу або в мобільних діагностичних комплексах, забезпечуючи опрацювання даних у захищеному контурі.

Недоліком наявних підходів є ігнорування двох аспектів медичного тексту, які не можуть бути повноцінно вивчені лише на основі текстових корпусів:

– онтологічна зв'язність: терміни можуть бути лексично різними, але семантично тісно пов'язаними через таксономічні відношення (синонімія, гіпонімія, причинно-наслідкові зв'язки), які містяться в зовнішніх базах знань, але не завжди представлені в навчальній вибірці;

– модальність та заперечення: у медицині наявність симптому («є кашель») та його відсутність («немає кашлю») радикально змінюють зміст і діагностичний висновок, хоча лексична схожість таких речень залишається надзвичайно високою.

З огляду на медичну специфіку предметної області, у межах дослідження під терміном «аналіз тональності», який традиційно використовується в технічній літературі з NLP, розуміється аналіз клінічної полярності та модальності. Це

включає визначення того, чи є медичний концепт наявним, відсутнім, можливим або таким, що стосується когось іншого.

У дослідженні використано інструмент MetaMap [130] для опрацювання англійських біомедичних текстів та прив'язки їх до уніфікованого метатезауруса (UMLS) [132]. Оскільки здебільшого еталонні набори даних для навчання та валідації медичного AI (наприклад, MIMIC-CXR, MedNLI) є англійськими, розроблення та первинна верифікація методу проводилася саме англійською мовою для забезпечення порівнюваності результатів зі світовими аналогами.

Водночас архітектура розробленої інтелектуальної інформаційної системи має передбачати модульність. Відповідно компонент MetaMap не є жорстко інтегрованим і може бути замінений на будь-який інший NER-модуль, адаптований під конкретну мову (наприклад, для української мови може бути використаний модуль на основі mBERT або XLM-R, донавчений на корпусі UA-Med). Така гнучкість дає змогу масштабувати метод без зміни ядра алгоритму NLI.

Для застосування запропонованого методу в українському мовному просторі передбачено використання модуля попереднього нейромережевого машинного перекладу на основі спеціалізованих моделей (наприклад, NLLB-200 або mBART), донавчених на паралельних медичних корпусах. Такий підхід дає змогу використовувати потужний аналітичний апарат UMLS/MetaMap для українських текстів. Водночас варто зауважити, що це вносить певні обмеження: додаткову часову затримку та залежність точності від якості перекладу, що враховано при аналізі кінцевих похибок системи.

З огляду на вказані вище вимоги до інтелектуальної інформаційної системи, опишемо коротко основні компоненти методу.

1. BioELMo [141]: базовий кодувальник тексту. На відміну від статичних ембедінгів (Word2Vec, GloVe), BioELMo генерує контекстуалізовані вектори, які є необхідними для розрізнення омонімів у медицині (наприклад, скорочення «Ca» може означати «Calcium» або «Carcinoma» залежно від контексту).

2. MultE [22]: механізм вбудовування графів знань. На відміну від простіших моделей типу TransE, модель MultE здатна кодувати складні відношення, як от

«багато-до-багатьох» та несиметричні зв'язки (наприклад, «лікує», «викликає», «діагностує»), що є характерним для структури медичних онтологій.

3. MetaMap: вилучення концептів та аналізу заперечень. З огляду на відому ресурсомісткість MetaMap та потенційні затримки при обробці великих масивів даних, у системі реалізовано механізми кешування результатів для часто вживаних фраз, що дає змогу оптимізувати час відгуку системи.

2.2.2 Структура методу та механізми інтеграції онтологічних знань

Запропонована архітектура методу ґрунтується на модифікованій моделі ESIM [140], яка доповнюється паралельними каналами опрацювання онтологічної інформації та модальності.

Загальна схема класифікації пар засновок-гіпотеза подана на рис. 2.6.

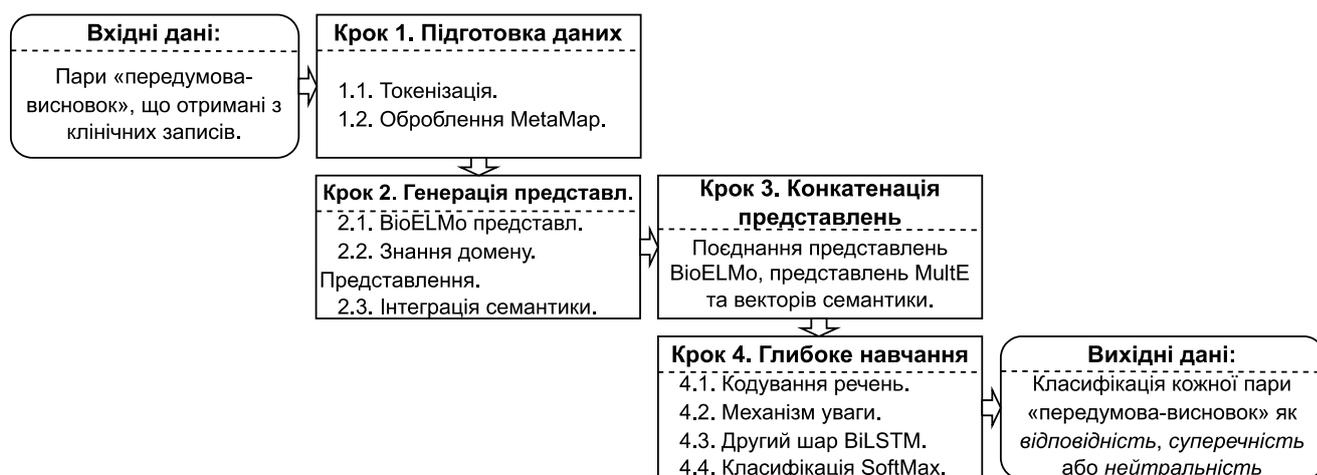


Рисунок 2.6 – Загальна схема класифікації пар засновок-гіпотеза

Детальний опис компонентів та їхнє функціональне призначення наведено в табл. 2.5.

Основним науковим внеском є розроблення механізму «м'якої» інтеграції знань, який дає змогу системі використовувати експертний досвід, але не залежати від нього у випадку помилок допоміжних інструментів або неповноти бази знань.

Компоненти нейромережевої архітектури за удосконаленням OPNI

Компонент	Функціональне призначення
BioELMo	Генерація контекстуальних векторів слів на основі корпусу PubMed
MetaMap	Вилучення медичних концептів UMLS та ідентифікація заперечень
MultE	Формування векторів вбудовування для концептів з графа знань
Sentiment Vector	Бінарне кодування тональності: 0 – позитивна / нейтральна, 1 – негативна / заперечення
Attention Mechanism	Динамічне зважування важливості кожного типу вбудовування
BiLSTM	Кодування послідовностей засновку та гіпотези з урахуванням контексту

Подамо покрокове функціонування запропонованого методу.

Вхідними даними методу є пара речень природною мовою (P, H) , де P – засновок, H – гіпотеза; база знань UMLS; навчені моделі BioELMo та MultE.

Крок 1. Попереднє опрацювання та ідентифікація концептів. Вхідні речення проходять процедуру токенизації, у результаті якої отримуємо послідовність токенів w_i . Паралельно виконується запит до інструменту MetaMap для ідентифікації медичних концептів UMLS у тексті та отримання їхніх унікальних ідентифікаторів.

У випадку, якщо MetaMap не повертає жодного концепту для токена через помилку розпізнавання, друкарську помилку або відсутність терміну в базі, або якщо інструмент недоступний, системі присвоюється спеціальний нульовий вектор знань $\mathbf{0}_{KG}$. Це забезпечує відмовостійкість методу: у такому сценарії модель автоматично переходить у режим роботи, що спирається виключно на лексичні контекстуальні вектори BioELMo, запобігаючи збою класифікації.

Крок 2. Генерація гібридних векторних представлень. Для кожного токена w формується композитний вектор ознак, що синтезується з трьох джерел:

– лексичний контекст: вектор $\mathbf{e}_{\text{BioELMo}}^w \in \mathbb{R}^{1024}$, отриманий із виходу моделі BioELMo, який кодує синтаксичну та контекстуальну інформацію;

– онтологічне знання: вектор $\mathbf{e}_{\text{MultE}}^w \in \mathbb{R}^{100}$; цей вектор генерується моделлю вбудовування графів MultE, попередньо навченою на релевантному підграфі UMLS; функція оцінки правдоподібності трійки фактів (h, r, t) у MultE формалізована у такий спосіб:

$$\phi(h, r, t) = (\mathbf{W}_r \mathbf{r} + \mathbf{b}_r) + [(\mathbf{W}_h \mathbf{h} + \mathbf{b}_h) \odot (\mathbf{W}_t \mathbf{t} + \mathbf{b}_t)], \quad (2.20)$$

де $\mathbf{h}, \mathbf{t}, \mathbf{r}$ – вектори сутностей (head, tail) та відношень (relation), \mathbf{W} та \mathbf{b} – параметри проєкцій, що навчаються, \odot – операція поелементного множення; використання мультиплікативних взаємодій дає змогу краще моделювати складну семантику медичних відношень порівняно з адитивними моделями (TransE).

– вектор модальності: вектор \mathbf{s}^w , який явно кодує інформацію про наявність заперечення або ствердження (процес формування описано в п. 2.2.3).

Крок 3. Адаптивна інтеграція. Оскільки не всі слова в реченні є медичними термінами (наприклад, службові частини мови), просте конкатенування векторів може внести значний шум. Для вирішення цієї проблеми застосовується механізм уваги, який адаптивно зважує важливість кожного компонента. Результуючий вектор \mathbf{e}^{ww} обчислюється як зважена сума у такий спосіб:

$$\mathbf{e}^{ww} = \sum_{k=1}^3 a_k \mathbf{v}_k, \quad (2.21)$$

де \mathbf{v}_k – проєктовані в спільний простір вектори компонентів (BioELMo, MultE, Modality), а ваги a_k розраховуються через функцію Softmax:

$$a_k = \frac{\exp(f_{\text{att}}(\mathbf{v}_k))}{\sum_{j=1}^3 \exp(f_{\text{att}}(\mathbf{v}_j))}. \quad (2.22)$$

Такий підхід дає змогу нейронній мережі динамічно ігнорувати онтологічний вектор, якщо він є неінформативним (нульовим) або суперечить контексту, що значно знижує залежність від помилок зовнішніх баз знань. Ілюстрація процесу об'єднання наведена на рис. 2.7.

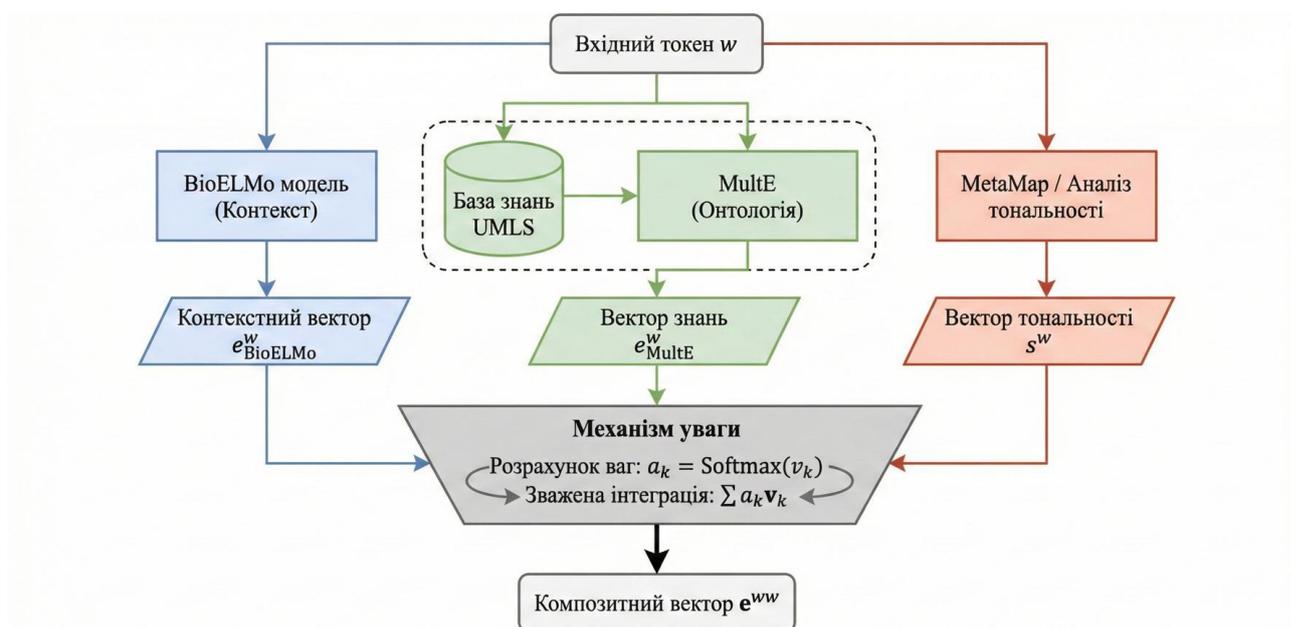


Рисунок 2.7 – Схема формування композитного векторного представлення токена через злиття контекстуальних (BioELMo), онтологічних (MultE) та ознак клінічної полярності/модальності (Sentiment Vector) через механізм вирівнювання

Крок 4. Контекстне кодування та вирівнювання. Отримані інтегровані вектори подаються на вхід двонаправленої рекурентної мережі (BiLSTM) для врахування послідовності слів у реченні (див. рис. 2.8).

Для моделювання локальних логічних зв'язків між словами засновку (приховані стани \bar{p}_i) та гіпотези (приховані стани \bar{h}_j) обчислюється матриця уваги \mathbf{A}_{ij} у такий спосіб:

$$\mathbf{A}_{ij} = \bar{p}_i^T \bar{h}_j. \quad (2.23)$$

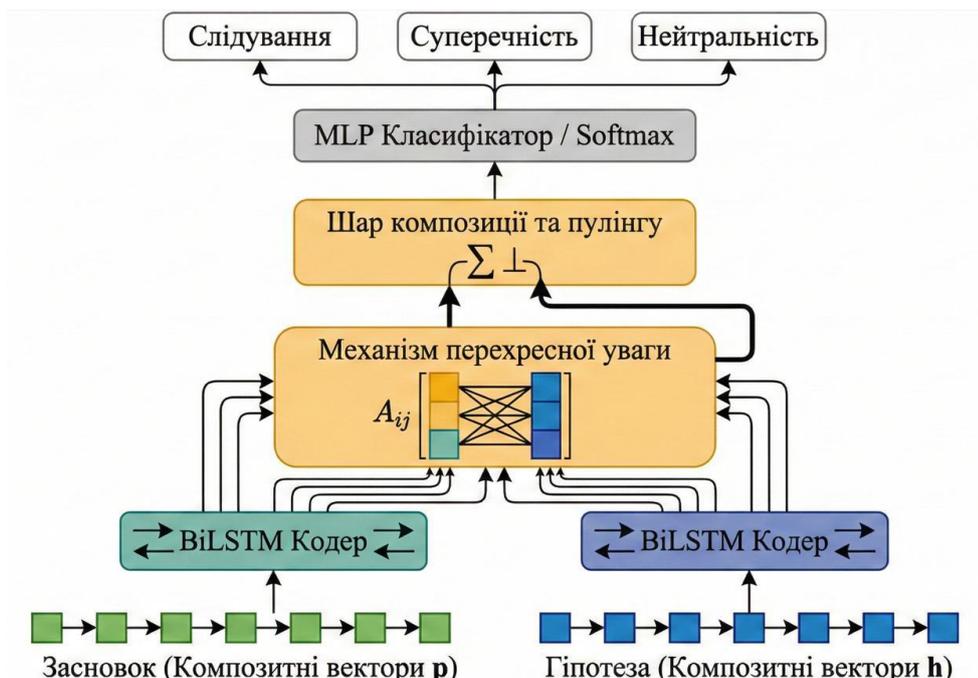


Рисунок 2.8 – Архітектура BiLSTM в удосконаленому методі OPNI: два потоки кодування (засновок/гіпотеза), механізм перехресної уваги та шар класифікації

Ця матриця, що проілюстрована на рис. 2.9, дає змогу моделі «зрозуміти», які саме фрагменти засновку підтверджують або спростовують конкретні частини гіпотези, забезпечуючи інтерпретованість прийнятих рішень.

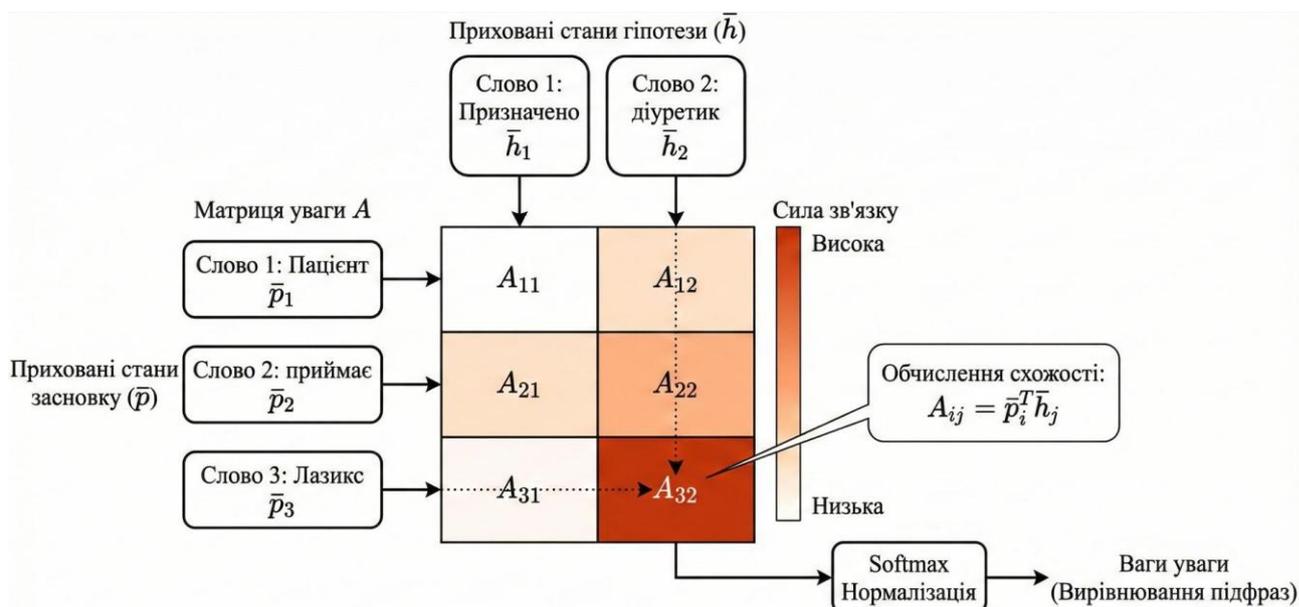


Рисунок 2.9 – Деталізація механізму уваги в моделі ESIM, який обчислює матрицю схожості між словами засновку та гіпотези для встановлення локальних висновків

Приклад структури графа знань UMLS, що використовується для генерації векторів MultE, наведено на рис. 2.10. Ця структурована інформація дає змогу моделі виявляти неявні зв'язки, наприклад, встановлювати, що препарат «Амоксицилін» належить до групи «Антибіотиків» або використовується для лікування «Пневмонії».

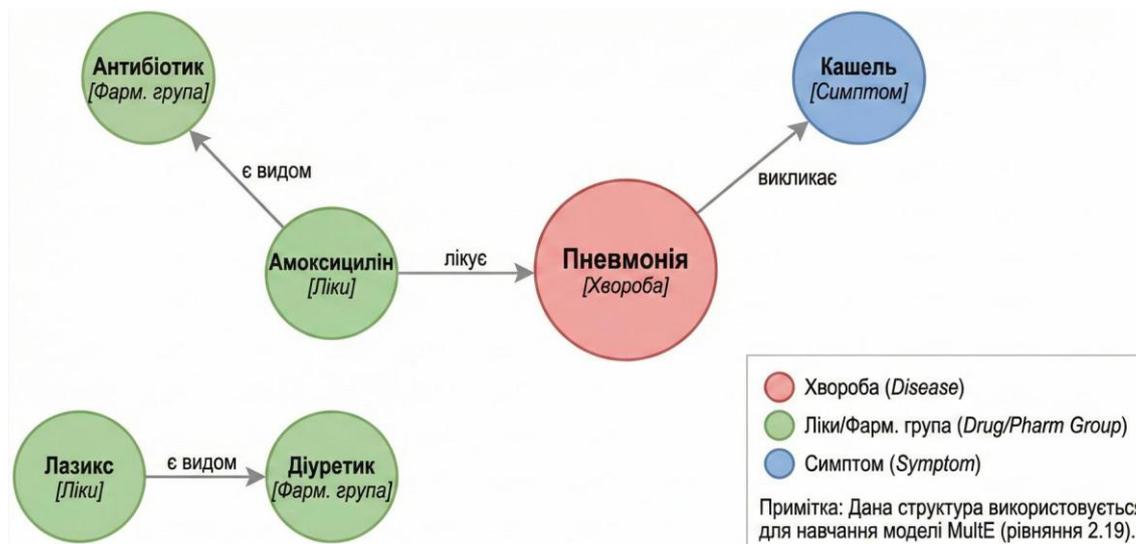


Рисунок 2.10 – Фрагмент графа знань UMLS, що демонструє семантичні типи та відношення між медичними поняттями в моделі MultE

Крок 5. Класифікація. Агрегований вектор представлення пари речень $\mathbf{v}_{\text{final}}$ формується через операції субдискретизації (англ. «pooling») та подається на класифікатор БШП.

Вихідними даними методу є розподіл ймовірностей $P(y|P, H)$ для класів $\{E, C, N\}$, обчислений через фінальний шар Softmax:

$$y = \text{Softmax}(\mathbf{W}_{\text{БШП}} \mathbf{v}_{\text{final}} + \mathbf{b}_{\text{БШП}}). \quad (2.24)$$

2.2.3 Алгоритмічне забезпечення аналізу модальності та опрацювання заперечень

У медичному діагностуванні необхідно розрізнити наявність симптому та його заперечення. Стандартні моделі NLP часто ігнорують частку «не» або

обробляють її як звичайне слово, що призводить до помилок; наприклад, класифікації суперечності як слідування.

Введемо поняття вектора клінічної полярності через s^w . Вектор s^w формується, у результаті виконанні таких кроків.

1. Виявлення заперечень. Інструмент MetaMap, використовуючи вбудований алгоритм NegEx, аналізує синтаксичну структуру речення та визначає область дії заперечень. Наприклад, у фразі «Пацієнт не має ознак пневмонії», область дії заперечення поширюється на термін «пневмонія».

2. Кодування. Інформація про полярність кодується в бінарний вектор або скаляр для кожного токена:

– $s^w = 0$: позитивна полярність (твердження про наявність симптому чи хвороби);

– $s^w = 1$: негативна полярність (заперечення наявності) або невизначеність.

3. Інтеграція. Вектор s^w подається як окремий вхід до механізму уваги (див. формулу (2.21)), що дає змогу моделі явно враховувати статус заперечення при формуванні семантичного представлення слова.

Удосконалений механізм опрацювання настрою та виявлення заперечень дає змогу системі правильно інтерпретувати складні лінгвістичні конструкції, які змінюють сенс медичних тверджень (наприклад, «немає кашлю» проти «є кашель»). Для явного кодування інформації про заперечення та настрою використовується інструмент MetaMap. Механізм формування вектора заперечень на основі виводу MetaMap проілюстрований на рис. 2.11.

Залежність від зовнішніх інструментів та мовний аспект. Інструмент MetaMap, хоч і є потужним засобом для вилучення медичних концептів та виявлення заперечень, розроблений переважно для англійської мови. Це створює значне обмеження при його застосуванні до українських медичних текстів. Для роботи з україномовними даними необхідно або використовувати надійну систему машинного перекладу медичних текстів на англійську мову перед опрацюванням MetaMap або задіювати аналогічні україномовні інструменти NLP для виявлення заперечень та медичних концептів, якщо такі існують та мають

достатню якість. Обидва варіанти мають свої недоліки: переклад може призвести до втрати клінічних нюансів та двозначності, тоді як спеціалізовані українські інструменти можуть бути менш зрілими або не мати повної підтримки для всіх необхідних медичних онтологій.

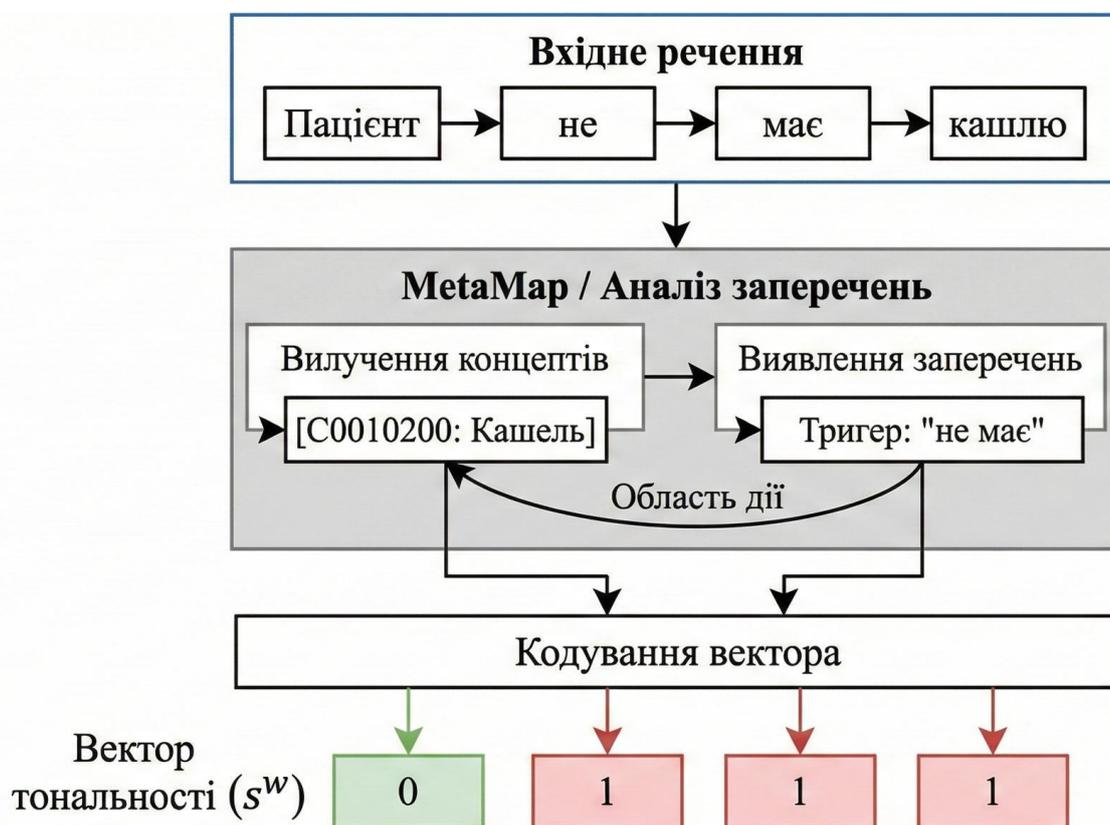


Рисунок 2.11 – Логіка формування вектора сентименту та заперечень на основі виводу MetaMap: виявлення заперечень та їхнє кодування в бінарний вектор

Крім того, результативність запропонованого методу залежить від якості роботи інструменту MetaMap при вилученні концептів та повноти бази знань UMLS. Помилки на етапі препроцесингу, такі як неправильне вилучення медичних концептів або хибне визначення заперечень інструментом MetaMap, можуть призвести до каскадного поширення помилок на наступні етапи аналізу через механізм уваги (див. формулу (2.22)). Це особливо актуально для рідкісних медичних термінів або складних клінічних описів, де MetaMap може мати обмежену точність.

Інструмент MetaMap відомий своєю ресурсомісткістю та повільною роботою, що може стати «вузьким місцем» під час опрацювання великих масивів

клінічних записів у реальному часі. У роботі не наведено оцінки часових затримок, які вносить саме цей компонент, що є важливим аспектом для практичного впровадження системи в медичні діагностичні комплекси, де швидкість прийняття рішень має значення. Для подальшого вдосконалення методу необхідно дослідити оптимізацію або альтернативні, більш продуктивні інструменти для виявлення заперечень та вилучення концептів.

Попри ці обмеження, запропонований механізм явного кодування сентименту та заперечень у вигляді спеціалізованих векторів, які інтегруються з лексичними та онтологічними ембедінгами через механізм уваги, є значним кроком до підвищення надійності інтерпретації клінічних записів. Він дає змогу системі ідентифікувати медичні концепти та точно розрізнити їхній модальний статус (наявність/відсутність), що необхідно для формування логічно узгоджених діагностичних гіпотез.

Узагальнюючи, запропоновані в розділі 2 методи створюють надійний фундамент для гібридних інтелектуальних систем, забезпечуючи високу точність унаслідок складнішого етапу навчання та залежності від зовнішніх баз знань. Такий компроміс є виправданим для медичних застосувань, де ціна помилки є високою.

2.3. Висновки до розділу 2

У другому розділі викладено та обґрунтовано удосконалений ЕМТКД. Запропонований підхід ґрунтується на використанні динамічного ансамблю моделей-вчителів у поєднанні з алгоритмами змагальної адаптації домену. Особливістю методу є впровадження механізму селективної фільтрації на основі індикаторної функції, який дає змогу динамічно відсіювати некоректні передбачення від окремих моделей-джерел. Такий архітектурний підхід забезпечує оптимізовану передачу узагальненого досвіду з гетерогенних джерел до єдиної компактної моделі-учня. Це дає можливість нівелювати наслідки доменного зсуву та підвищити точність ідентифікації патологій серця за умов обмеженої кількості розмічених зразків у цільовому наборі даних. Окрім того, відокремлене локальне

розгортання моделі-учня на етапі інференсу гарантує дотримання вимог щодо конфіденційності медичних даних пацієнтів.

Також у другому розділі подано удосконалений метод OPNI. Метод реалізує інтеграцію онтологічних знань із бази UMLS та аналізу клінічної тональності безпосередньо в архітектуру нейронної мережі. Запропонована гібридна структура ґрунтується на синергетичному використанні моделі BioELMo для генерації контекстуальних векторів слів та графової моделі MultE для формування математичних вбудовувань медичних концептів. Впроваджений модуль явного кодування модальності дає можливість системі розрізняти специфічні лінгвістичні конструкції. Злиття цих ознак через механізм перехресної уваги дає змогу мережі коректно враховувати ієрархічні семантичні зв'язки між медичними поняттями та безпомилково інтерпретувати заперечення в клінічних записах, що є критично необхідним для точного автоматизованого аналізу електронних історій хвороби.

У межах розділу теоретично обґрунтовано математичні моделі розроблених методів, детально формалізовано складені цільові функції втрат та математичний апарат механізмів уваги. Описані методи дистиляції просторових ознак та семантичного текстового аналізу створюють цілісну методологічну основу для проєктування багатомодальних адаптивних діагностичних комплексів. Розроблені методи здатні опрацьовувати візуальну радіологічну та неструктуровану текстову медичну інформацію, забезпечуючи клінічну обґрунтованість процесу прийняття рішень.

Основні результати розділу опубліковані в працях [26, 27, 31, 33, 34].

РОЗДІЛ 3.

МЕТОДИ ІНТЕГРАЦІЇ ЗНАНЬ ДІАГНОСТИЧНИХ МОДЕЛЕЙ В АРХІТЕКТУРИ ГЛИБОКОГО НАВЧАННЯ МЕДИЧНИХ СИСТЕМ

У третьому розділі сформовано теоретико-методологічні засади інтеграції діагностичних моделей в архітектури глибокого навчання. Обґрунтовано необхідність переходу до гібридної парадигми навчання, інформованого знаннями, що дозволяє звузити простір допустимих рішень та уникнути типових топологічних помилок. Наведено математичну формалізацію інтеграції апріорних знань у стохастичні моделі як задачі умовної оптимізації.

Запропоновано та описано новий метод сегментації зображень МРТ серця, який ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги та спеціалізованої функції втрат із топологічними обмеженнями. Запропонований підхід, на відміну від стандартних архітектур, використовує функції знакової відстані для гарантування анатомічної коректності результатів, зокрема вкладеності та суміжності структур серця.

У третьому розділі також наведено опис нового методу ідентифікації патологій серця за зображенням МРТ з використанням GCN, що реалізує парадигму реляційного міркування на графах, де вузли інтегрують гібридні візуальні та морфологічні ознаки, а ребра кодують діагностичні знання. Запропоновано новий спосіб побудови матриці суміжності як суперпозиції просторових зв'язків та діагностичних кореляцій, отриманих із медичних настанов, що забезпечує врахування значущих залежностей.

Уперше використано механізм глобальної субдискретизації уваги в контексті серцевих графів, що забезпечує інтерпретованість рішень через визначення вкладу кожного анатомічного сегмента у фінальний діагноз. Створено математичний апарат для реалізації запропонованих методів, який охоплює модулі попередньої обробки, генерації карт відстаней та навчання GCN.

3.1. Формалізація інтеграції апріорних знань у стохастичні моделі

Сучасна парадигма побудови систем підтримки прийняття лікарських рішень у медичних діагностичних комплексах переживає фундаментальну трансформацію, зумовлену переходом від детермінованих експертних систем до імовірнісних моделей DL. Попри переваги CNN та трансформерних архітектур у задачах розпізнавання образів, їхнє практичне впровадження у клінічну практику стримується низкою вагомих чинників, поміж яких виділяється проблема інтерпретованості або так званий ефект «чорної скриньки», низька стійкість до збурень та висока залежність від обсягу анотованих даних, які у медичній галузі є дефіцитним ресурсом.

Загальна наукова гіпотеза даного розділу дисертаційної роботи базується на твердженні, що подолання зазначених обмежень можливе лише шляхом переходу від чистої парадигми навчання на основі даних до гібридної парадигми навчання, інформованого знаннями. Відповідно розглянемо інтеграцію знань не як евристичне доповнення, а як математично обґрунтовану модифікацію простору пошуку рішень моделі.

Формалізуємо задачу навчання нейронної мережі як пошук оптимального набору параметрів $\theta^* \in \mathbb{R}^d$, що мінімізує функціонал емпіричного ризику $\mathcal{R}_{\text{emp}}(\theta)$ на навчальній вибірці $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^N$:

$$\theta^* = \arg \min_{\theta \in \Theta} \frac{1}{N} \sum_{i=1}^N \mathcal{L}(f(x_i; \theta), y_i), \quad (3.1)$$

де \mathcal{L} – функція втрат (наприклад, перехресна ентропія), а f – функція, що апроксимується мережею.

У медичних задачах, де розмірність простору ознак x_i значно перевищує кількість зразків N (прокляття розмірності), простір розв’язків Θ містить велику кількість локальних мінімумів, які забезпечують нульову помилку на навчальній

вибірці, але не гарантують узагальнення на генеральній сукупності, що призводить до перенавчання.

Запропонований у цьому розділі підхід полягає у звуженні простору допустимих рішень через введення індуктивного зміщення, що базується на верифікованих медичних знаннях \mathcal{K} . Розглянемо знання \mathcal{K} як набір обмежень або регуляризаторів, що трансформують задачу безумовної оптимізації у задачу умовної оптимізації або Байєсівського виведення з апіорним розподілом $P(\theta | \mathcal{K})$.

Тоді цільова функція модифікується так:

$$\theta_{\text{informed}}^* = \arg \min_{\theta \in \Theta} (\mathcal{L}_{\text{data}}(\theta; \mathcal{D}) + \lambda \mathcal{R}_{\text{knowledge}}(\theta; \mathcal{K})), \quad (3.2)$$

де $\mathcal{R}_{\text{knowledge}}$ – функціонал, що оцінює ступінь узгодженості моделі з базою знань, а λ – коефіцієнт Лагранжа, що регулює вплив знань.

У третьому розділі теоретично обґрунтовано та подано опис двох нових методів, які реалізують концепцію інтеграції доменних знань на різних рівнях абстракції даних:

- на рівні піксельного оброблення: розроблено метод сегментації зображень МРТ серця, який безпосередньо інтегрує просторові експертні знання та топологічні обмеження в процес виділення анатомічних структур;

- на рівні семантичного аналізу об’єктів: запропоновано метод ідентифікації патологій серця за зображеннями МРТ, що впроваджує реляційні діагностичні закономірності в алгоритм класифікації клінічних станів.

Обидва підходи підпорядковані досягненню мети дослідження, а саме підвищенню точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах. Такий результат забезпечується через математичну формалізацію накопиченого медичного досвіду та його включення в нейромережеве моделювання. Нижче наведено розгорнутий опис розроблених методів, подано їхню строгую математичну формалізацію, деталізовано алгоритмічну реалізацію та проаналізовано отримані експериментальні результати.

3.2. Метод сегментації зображень МРТ серця

Сегментація анатомічних структур серця на зображеннях МРТ слугує важливим етапом у циклі кардіологічного діагностування, оскільки точність цього процесу безпосередньо впливає на достовірність розрахунку клінічних показників, таких як фракція викиду, ударний об'єм та маса міокарда [55]. Попри значний прогрес у задачах сегментації, досягнутий завдяки використанню CNN, зокрема архітектури U-Net [13], стандартні підходи, що ґрунтуються на піксельній оптимізації метрик, часто ігнорують глобальні топологічні властивості біологічних об'єктів. Це призводить до виникнення анатомічно неможливих артефактів: розривів у кільці міокарда, появи ізольованих «острівців» тканин у порожнинах шлуночків або неприпустимого перетину областей, що мають бути розділеними.

У відповідь на зазначені вище виклики, у дисертаційній роботі розроблено новий метод сегментації зображень МРТ серця (англ. «**Synergistic Knowledge Integration Framework for Segmentation**», SKIF-Seg). Запропонований метод передбачає створення CNN, що ґрунтується на синергетичному поєднанні двох компонентів:

1) механізм експертно-керованої уваги (англ. «**Expert-Guided Attention**», EGA): модуль, що інтегрує явні просторові пріори (карти уваги, згенеровані на основі знань експертів про типові зони помилок) у процес вилучення ознак, що дає змогу моделі фокусуватися на складних ділянках;

2) механізм функції втрат із топологічними обмеженнями (англ. «**Topologically-Aware Anatomical Constraints**», ТААС): спеціалізована функція втрат, що ґрунтується на диференційовних перетвореннях відстані та морфологічних операціях, призначена для штрафування моделі за порушення топологічної цілісності.

Загальну архітектуру системи, що демонструє взаємодію між модулями сегментації та класифікації у межах двоетапного оброблення зображення МРТ серця, подано на рис. 3.1.

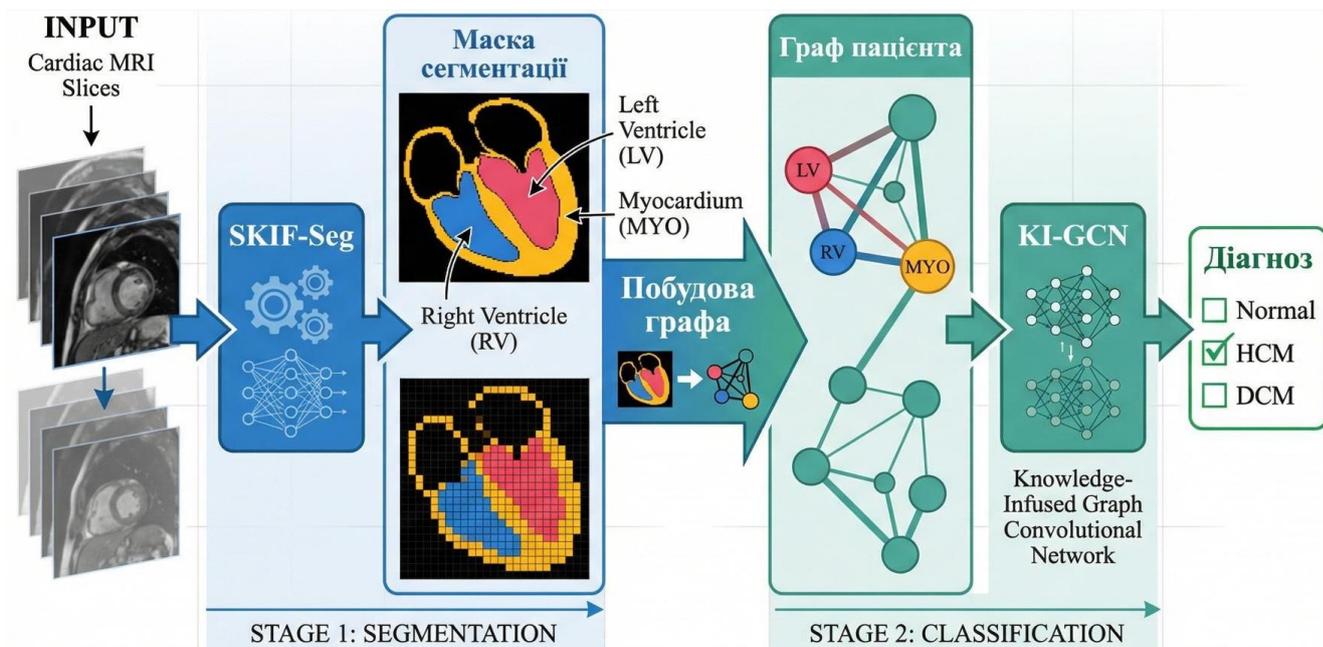


Рисунок 3.1 – Загальна схема запропонованого двоетапного оброблення зображення МРТ серця: етап 1 – анатомічно обмежена сегментація за методом SKIF-Seg, етап 2 – класифікація з використанням GCN

Проблема жорсткої залежності в каскадній архітектурі, зображеній на рис. 3.1, створює потенційну точку відмови: будь-які помилки на етапі сегментації автоматично стають хибними вхідними даними для GCN під час ідентифікації патологій серця за зображенням МРТ. Саме тому запропонований метод SKIF-Seg спрямований на мінімізацію топологічних помилок, які є найбільш деструктивними для подальшої побудови графа суміжності.

3.2.1 Формалізація науково-прикладної задачі та обмежень

Розглянемо вхідне зображення $I: \Omega \rightarrow \mathbb{R}$, де $\Omega \subset \mathbb{R}^2$ – дискретна область визначення зображення (піксельна решітка). Задачею сегментації є відображення кожного пікселя $x \in \Omega$ у клас $c \in \mathcal{C} = \{0, \dots, K-1\}$, де K – кількість класів; для задачі сегментації серця $K=4$: фон, лівий шлуночок (ЛШ), міокард (Міо), правий шлуночок (ПШ).

Метод SKIF-Seg призначення для усунення проблеми невідповідності статистичної природи навчання CNN та детермінованої природи анатомічної топології. Стандартні функції втрат розглядають ймовірність приналежності пікселя до класу $P(y|x)$ як незалежну від сусідів, що призводить до порушення топологічних інваріантів. Сформуємо такі анатомічні обмеження, які мають виконуватися для коректної сегментації серця:

1) топологічне обмеження вкладеності (C1): порожнина ЛШ повинна бути повністю оточена Міо на всіх зрізах, де присутні обидві структури;

2) топологічне обмеження суміжності (C2): ПШ повинен бути суміжним із Міо, розділеним міжшлуночковою перегородкою, але не повинен перетинатися з порожниною ЛШ;

3) геометричне обмеження безперервності (C3): усі сегментовані області повинні бути однозв'язними, за винятком рідкісних випадків біфуркації на краях об'єму. Ілюстрація типових помилок та концепція їхнього виправлення наведена на рис. 3.2.

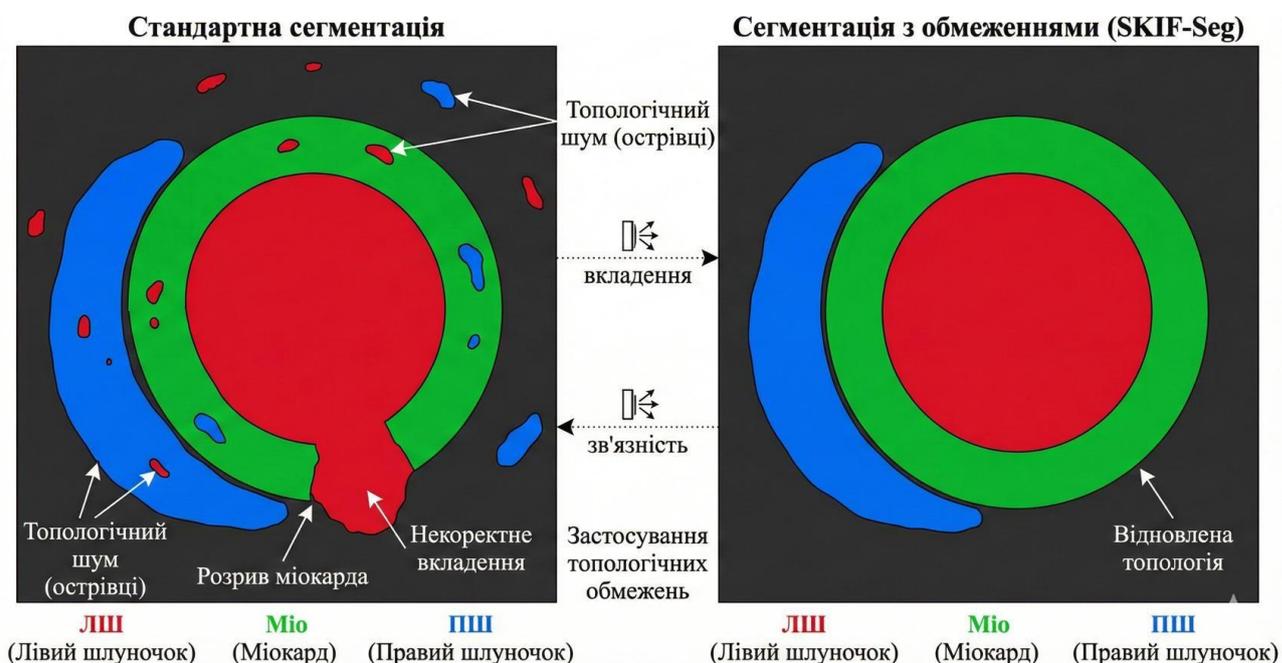


Рисунок 3.2 – Приклади типових топологічних помилок за стандартної сегментації (розриви Міо та некоректне вкладення) та концепція їхнього

виправлення за допомогою запропонованих обмежень

Варто зазначити, що введення штрафів за порушення топології значно ускладнює функцію втрат, роблячи її неопуклою, що може призводити до проблем зі збіжністю моделі. Для подолання цієї проблеми в роботі використано підхід на основі функцій знакової відстані (англ. «Signed Distance Functions», SDF), які мають кращі властивості гладкості порівняно з дискретними масками.

Для кожної анатомічної структури K визначимо прогнозовану карту ймовірностей $P_k(x)$ та SDF істинної маски $\Phi_k(x)$ (див. рис. 3.3). Властивість SDF полягає в тому, що $\Phi_k(x) < 0$ всередині об'єкта, $\Phi_k(x) > 0$ ззовні, а $|\Phi_k(x)|$ дорівнює відстані до найближчої точки границі $\partial\Omega_k$.

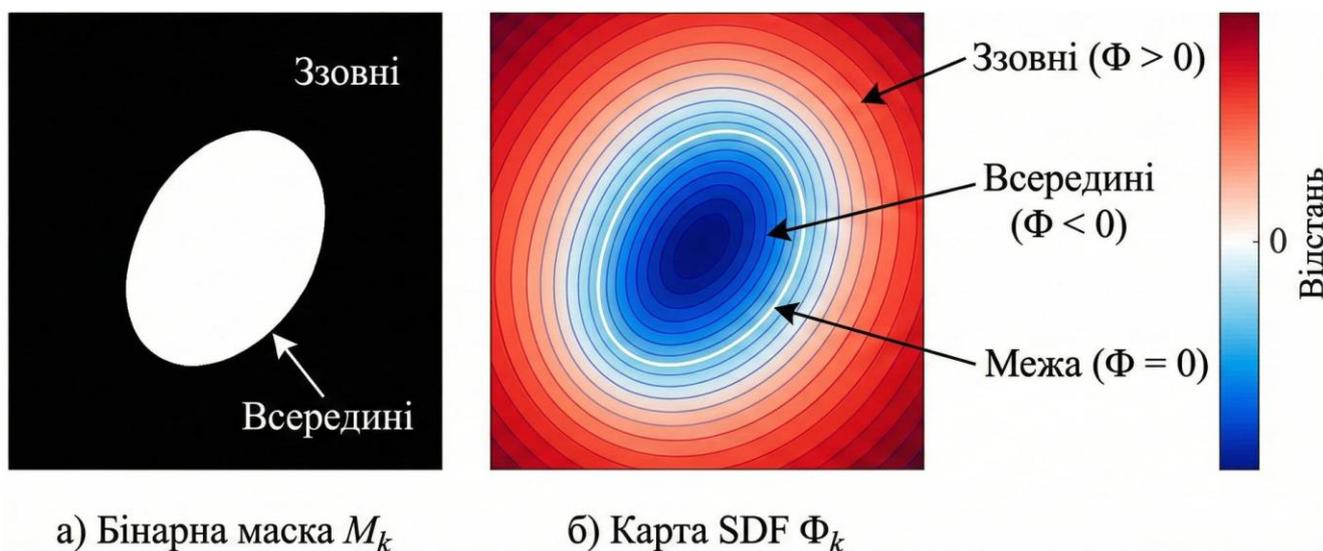


Рисунок 3.3 – Концепція SDF для анатомічних структур: а) бінарна маска та б) карта SDF, де значення відображають відстань до межі (негативні всередині, позитивні ззовні)

1. Втрата оточення, \mathcal{L}_{enc} . Нехай $\Phi_{\text{Mio}}^{\text{in}}(x)$ та $\Phi_{\text{Mio}}^{\text{out}}(x)$ – відстані до внутрішньої та зовнішньої меж Mio відповідно. Для забезпечення вкладеності ЛШ у Mio введено штраф для пікселів, класифікованих як ЛШ, що перебувають за межами зовнішнього контуру Mio в такий спосіб:

$$\mathcal{L}_{\text{enc}} = \sum_{x \in \Omega} P_{\text{LV}}(x) \cdot \text{ReLU}(\Phi_{\text{Mio}}^{\text{combined}}(x)), \quad (3.3)$$

де $\Phi_{\text{Mio}}^{\text{combined}}(x)$ – спеціально сконструйована карта відстаней, яка є додатною за межами зовнішнього контуру Mio.

2. Втрата суміжності, \mathcal{L}_{adj} . Для забезпечення анатомічно коректного контакту між ПШ та Mio без їхнього взаємного перекриття, використано спеціалізовану функцію втрат:

$$\mathcal{L}_{\text{adj}} = \sum_{x \in \Omega} P_{\text{ПШ}}(x) \cdot \exp(-\alpha \cdot |\Phi_{\text{Mio}}(x)|) \cdot \mathbb{I}(\Phi_{\text{Mio}}(x) > 0), \quad (3.4)$$

де $x \in \Omega$ – просторова координата пікселя в області визначення зображення Ω , $P_{\text{ПШ}}(x)$ – прогнозована мережею ймовірність приналежності пікселя x до класу ПШ, $\Phi_{\text{Mio}}(x)$ – значення SDF для істинної маски Mio.

Відповідно до визначення SDF, $\Phi_{\text{Mio}}(x) > 0$ для точок, що перебувають зовні Mio, та $\Phi_{\text{Mio}}(x) \leq 0$ для точок всередині або на межі структури; α – позитивний гіперпараметр (коефіцієнт крутизни), що регулює радіус дії «магнітного» тяжіння до межі; $\mathbb{I}(\text{condition})$ – індикаторна функція, що набуває значення 1, якщо умова в дужках виконується, та 0 у протилежному випадку:

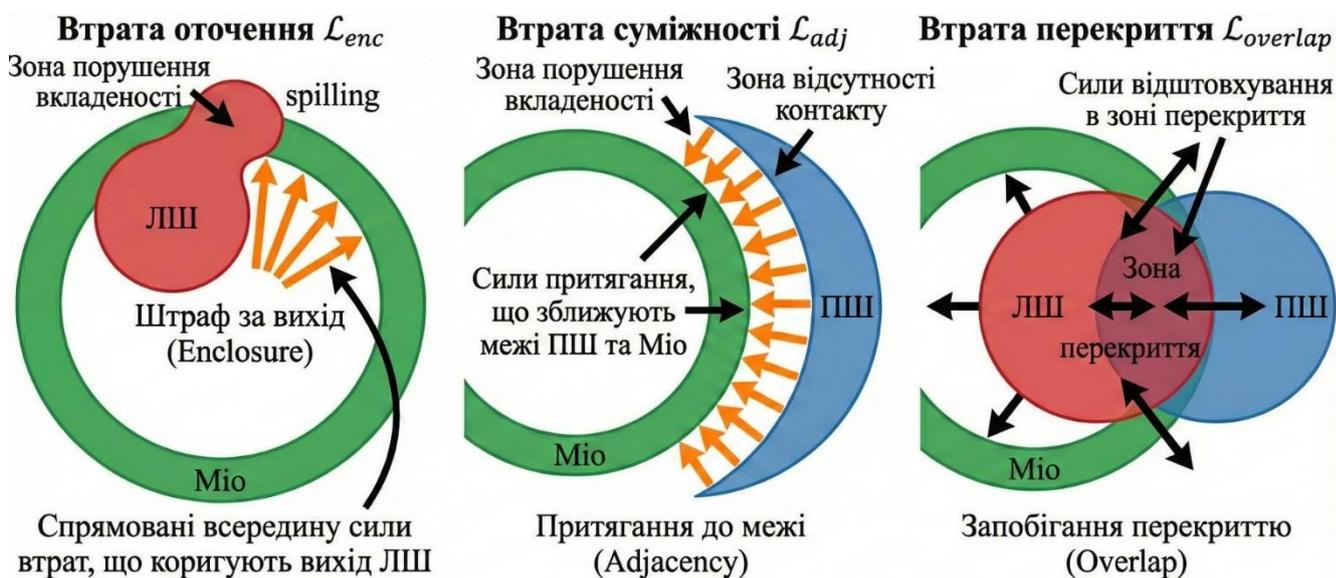
$$\mathbb{I}(\Phi_{\text{Mio}}(x) > 0) = \begin{cases} 1, & \text{якщо } x \text{ зовні міокарда;} \\ 0, & \text{якщо } x \text{ всередині або на межі міокарда.} \end{cases}$$

Експоненціальний член $\exp(-\alpha \cdot |\Phi_{\text{Mio}}(x)|)$ досягає максимуму, коли відстань до Mio наближається до нуля, що діє як «магніт», стимулюючи модель активувати клас ПШ безпосередньо поблизу межі Mio. Використання індикаторної функції $\mathbb{I}(\Phi_{\text{Mio}}(x) > 0)$ є критично важливим: вона обнуляє штраф, коли ПШ перебуває всередині Mio з погляду геометрії SDF, тим самим створюючи односторонній «бар'єр», який дає можливість ПШ торкатися Mio зовні, але забороняє будь-яке проникнення всередину його структури.

3. Втрата перекриття, $\mathcal{L}_{\text{overlap}}$. Для забезпечення чітких меж та уникнення ситуацій, коли піксель має високу ймовірність належності до кількох взаємовиключних класів (див. рис. 3.4), вводиться штраф, що формалізовано так:

$$\mathcal{L}_{\text{overlap}} = \sum_{(k,m) \in \mathcal{K}_{\text{conflict}}} \sum_{x \in \Omega} P_k(x) \cdot P_m(x), \quad (3.5)$$

де $\mathcal{K}_{\text{conflict}}$ – множина пар класів, що не можуть перетинатися, як от ЛШ та ПШ.



Червоний: ЛШ, Зелений: Міо, Синій: ПШ, Оранжеві стрілки: Сили ТААС, Чорні стрілки: Сили відштовхування

Рисунок 3.4 – Візуалізація дії компонентів функції втрат ТААС: \mathcal{L}_{enc} штрафует вихід ЛШ за межі Міо, \mathcal{L}_{adj} забезпечує прилягання ПШ, $\mathcal{L}_{\text{overlap}}$ запобігає перекриттю

Складність оптимізації такої багатокomпонентної функції втрат є значним викликом. Загальна цільова функція є зваженою сумою п'яти компонентів, що створює складний ландшафт оптимізації:

$$\mathcal{L}_{\text{Total}} = \mathcal{L}_{\text{Dice}} + \mathcal{L}_{\text{CE}} + \lambda_{\text{ТААС}}(t) (\mathcal{L}_{\text{enc}} + \mathcal{L}_{\text{adj}} + \mathcal{L}_{\text{overlap}}). \quad (3.6)$$

Коефіцієнт $\lambda_{\text{ТААС}}(t)$ залежить від часу навчання (епохи t) та забезпечує стабільність збіжності. Використання статичних ваг може призвести до того, що

топологічні обмеження домінуватимуть на ранніх етапах, заважаючи мережі вивчити базові ознаки зображення.

3.2.2 Структура методу та алгоритмічне забезпечення

Архітектура нейромережевої моделі за запропонованим методом SKIF-Seg ґрунтується на класичній архітектурі U-Net з кодувальником та декодувальником. У методі проведено заміну стандартних пропускових з'єднань (англ. «skip-connections») на модулі EGA. Схема архітектури за методом SKIF-Seg з інтегрованими модулями EGA проілюстровано на рис. 3.5.

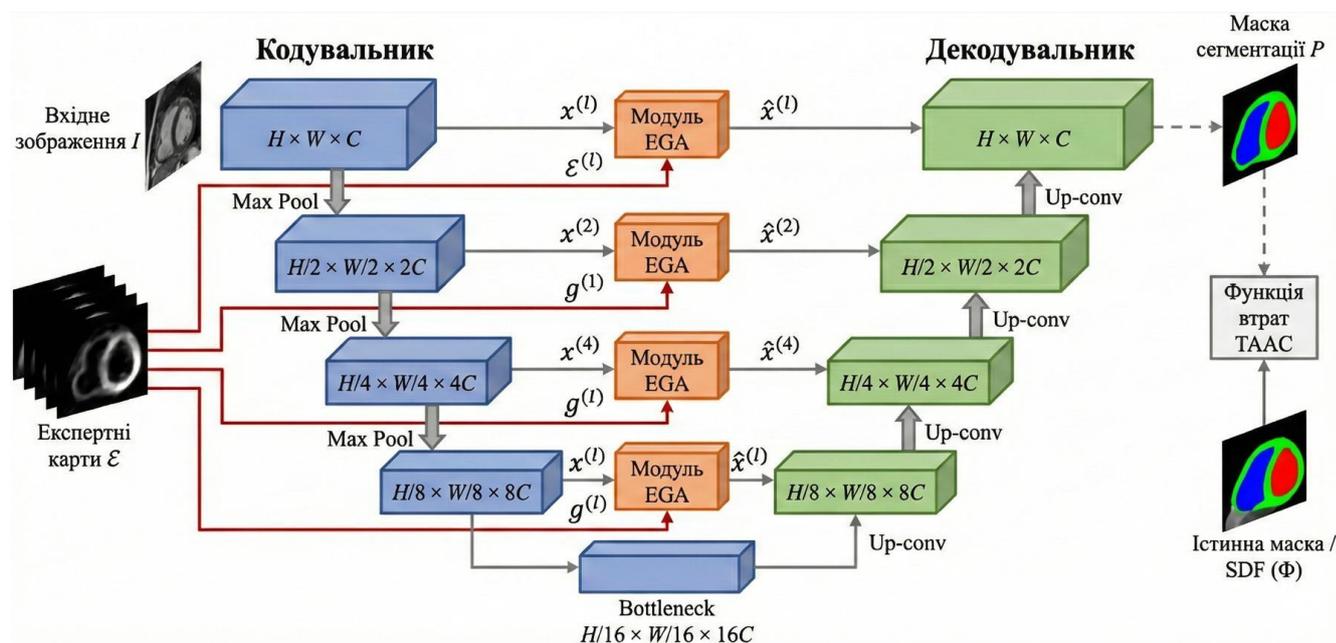


Рисунок 3.5 – Архітектура нейромережевої моделі за методом SKIF-Seg з інтегрованими модулями EGA та функцією втрат ТААС; показано потік інформації через пропускові з'єднання, що керований експертними картами

Нехай $x^{(l)} \in \mathbb{R}^{H_l \times W_l \times C_l}$ – карта ознак з l -го рівня кодувальника, а $g^{(l)} \in \mathbb{R}^{H_l \times W_l \times C_g}$ – сигнал стробування. В архітектурі за SKIF-Seg введено додатковий вхід – карту експертних знань $\mathcal{E}^{(l)}$, яка містить апіорну інформацію про ймовірність знаходження складних меж.

Математична модель модуля EGA, детальна схема якого наведена на рис. 3.6, описується в такий спосіб:

1) лінійна проєкція та інтеграція сигналів:

$$q_{\text{att}}^{(l)} = \sigma_1 \left(W_x x^{(l)} + W_g g^{(l)} + W_e \mathcal{E}^{(l)} + b_g \right), \quad (3.7)$$

де W_x, W_g, W_e – вагові матриці згорток 1×1 ;

2) генерація коефіцієнтів уваги:

$$\alpha^{(l)} = \sigma_2 \left(W_\psi q_{\text{att}}^{(l)} + b_\psi \right), \quad (3.8)$$

де $\alpha^{(l)} \in [0,1]$ – карта уваги;

3) модуляція ознак:

$$\hat{x}^{(l)} = \alpha^{(l)} \odot x^{(l)}. \quad (3.9)$$

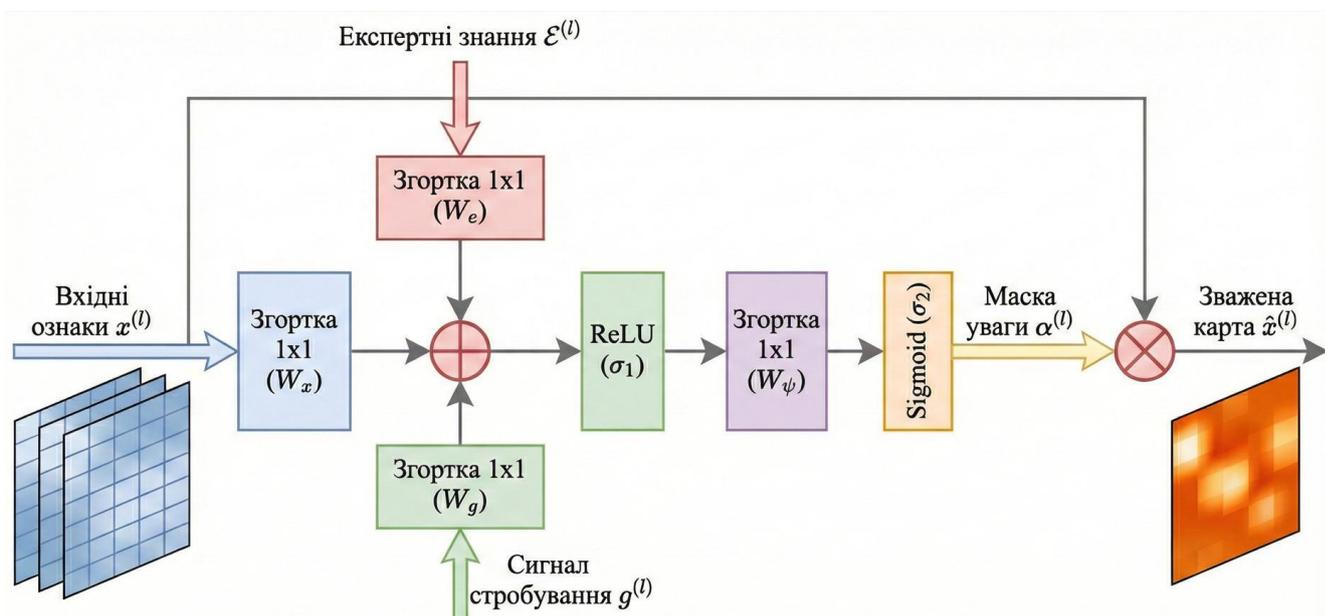


Рисунок 3.6 – Детальна схема модуля EGA, що демонструє об'єднання вхідних ознак, сигналу стробування та карти експертних знань для генерації маски уваги

Для забезпечення стабільної збіжності методу та вирішення проблеми чутливості до налаштування параметрів, розроблено стратегію динамічного зважування компонентів функції втрат.

Вага топологічних втрат $\lambda_{\text{ТААС}}(t)$ змінюється за сигмоїдальним законом у такий спосіб:

$$\lambda_{\text{ТААС}}(t) = \lambda_{\text{max}} \cdot \frac{1}{1 + e^{-k(t-t_0)}}, \quad (3.10)$$

де λ_{max} – цільове значення ваги, t_0 – епоха початку активного впливу топологічних обмежень, K – крутизна зростання; така стратегія дає змогу мережі спочатку сформулювати загальне уявлення про об'єкти на основі піксельних втрат ($\mathcal{L}_{\text{Dice}}, \mathcal{L}_{\text{CE}}$), а потім уточнити їхні межі та взаємне розташування.

Рекомендовані значення гіперпараметрів, отримані в результаті емпіричного дослідження на валідаційній вибірці, наведено в табл. 3.1.

Таблиця 3.1

Конфігурація гіперпараметрів навчання для нейромережевої моделі за SKIF-Seg

Параметр	Значення
Оптимізатор	Adam
Швидкість навчання	1×10^{-4}
Розмір батчу	8
Кількість епох	200
Коефіцієнт ваги, λ_{enc}	1,0
Коефіцієнт ваги, λ_{adj}	0,5
Коефіцієнт ваги, λ_{overlap}	0,5
Епоха початку «поступового прогрівання» (t_0)	50

Вибір значень для коефіцієнтів ваги $\lambda_{\text{enc}} = 1,0$, $\lambda_{\text{adj}} = 0,5$ та $\lambda_{\text{overlap}} = 0,5$ обумовлено балансом градієнтів: втрата вкладеності є найбільш суттєвою для

забезпечення анатомічної коректності, тому їй надається пріоритет, тоді як суміжність та перекриття діють як допоміжні регуляризатори.

Нижче наведено покрокове виконання методу.

Вхідними даними методу є набір навчальних даних $\mathcal{D} = \{(I_i, M_i, E_i)\}_{i=1}^N$, де I_i – зображення, M_i – маска, E_i – експертна карта.

Крок 1. Попереднє опрацювання та підготовка даних:

- 1) виконати нормалізацію інтенсивності зображень I_i (Z-score);
- 2) для кожної маски M_i згенерувати карти знакових відстаней Φ_k за допомогою алгоритму Евклідового перетворення відстані (англ. «Exact Euclidean Distance Transform», EDT); цей крок створює додаткове обчислювальне навантаження, проте він виконується лише під час навчання; натомість для прискорення процесу карти SDF можуть бути попередньо розраховані та збережені.

Крок 2. Ініціалізація моделі:

- 1) ініціалізувати ваги мережі θ методом He initialization;
- 2) встановити початкове значення $\lambda_{\text{TAAC}} = 0$.

Крок 3. Ітеративне навчання для кожної епохи $t = 1 \dots T$:

- 1) оновити коефіцієнт $\lambda_{\text{TAAC}}(t)$ згідно зі стратегією «поступове прогрівання»;
- 2) для кожного міні-батчу $B \subset \mathcal{D}$:
 - а) пряме поширення:
 - отримати карти ознак кодувальника $x^{(l)}$;
 - обчислити коефіцієнти уваги $\alpha^{(l)}$ в модулях EGA, використовуючи E_i ;
 - отримати прогноз ймовірностей $P = f_{\theta}(I_i, E_i)$;
 - б) обчислення втрат:
 - розрахувати базові втрати: $\mathcal{L}_{\text{Base}} = \mathcal{L}_{\text{Dice}}(P, M_i) + \mathcal{L}_{\text{CE}}(P, M_i)$;
 - розрахувати топологічні втрати $\mathcal{L}_{\text{TAAC}}$ за формулами (3.7)–(3.9), використовуючи карти Φ_k ;
 - обчислити загальну втрату: $\mathcal{L}_{\text{batch}} = \mathcal{L}_{\text{Base}} + \lambda_{\text{TAAC}}(t)\mathcal{L}_{\text{TAAC}}$;

в) зворотне поширення:

- обчислити градієнти $\nabla_{\theta} \mathcal{L}_{\text{batch}}$;
- оновити ваги: $\theta \leftarrow \theta - \eta \cdot \text{Adam}(\nabla_{\theta})$.

Вихідними даними методу є оптимізовані параметри нейронної мережі θ^* , що забезпечують сегментацію з дотриманням топологічних обмежень.

3.2.3 Аналіз обчислювальної стійкості та стратегії мінімізації похибок

Впровадження топологічних обмежень та механізмів уваги, попри покращення якості сегментації, створює певні виклики щодо обчислювальних ресурсів та стійкості системи.

По-перше, використання функції втрат ТААС вимагає обчислення карт SDF на кожній ітерації навчання (якщо використовується аугментація «динамічно»). Це збільшує час навчання порівняно зі стандартними підходами. Однак, важливо підкреслити, що ці накладні витрати стосуються виключно етапу навчання. На етапі інференсу (використання моделі) розрахунок SDF не потрібен, тому швидкість роботи навченої нейромережевої моделі за запропонованим методом SKIF-Seg є співмірною з класичною U-Net, відрізняючись лише незначними витратами на обчислення механізму EGA.

По-друге, апаратні вимоги для реалізації методу є доволі високими. Для навчання моделі з 3D згортками та динамічним розрахунком топологічних втрат використовувався графічний прискорювач NVIDIA GPU RTX 3080. Це може суперечити вимозі щодо використання системи в мобільних діагностичних комплексах. Рішенням цієї суперечності є розділення етапів: навчання відбувається на високопродуктивних серверах, а для розгортання на кінцевих пристроях застосовується квантування моделі (або дистиляція знань), що описана в п. 2.1.2, яка дає змогу суттєво зменшити вимоги до ресурсів без значної втрати точності.

Також варто звернути увагу на ризик поширення похибки у каскадній архітектурі системи. Оскільки результати сегментації за методом SKIF-Seg є вхідними даними для GCN, що здійснює ідентифікацію патологій серця за

зображенням МРТ, будь-яка помилка сегментації (наприклад, некоректне визначення об'єму ЛШ) може призвести до хибного діагнозу. Система не має вбудованого механізму автоматичного виправлення грубих помилок сегментації на етапі класифікації. Для мінімізації цього ризику метод SKIF-Seg налаштовано на метрику відстані Хаусдорфа (англ. «5th percentile Hausdorff distance», HD95) та топологічну цілісність, що має на меті забезпечити правильність побудови графа, на відміну від простої піксельної точності.

Якісне порівняння результатів сегментації подано на рис. 3.7.

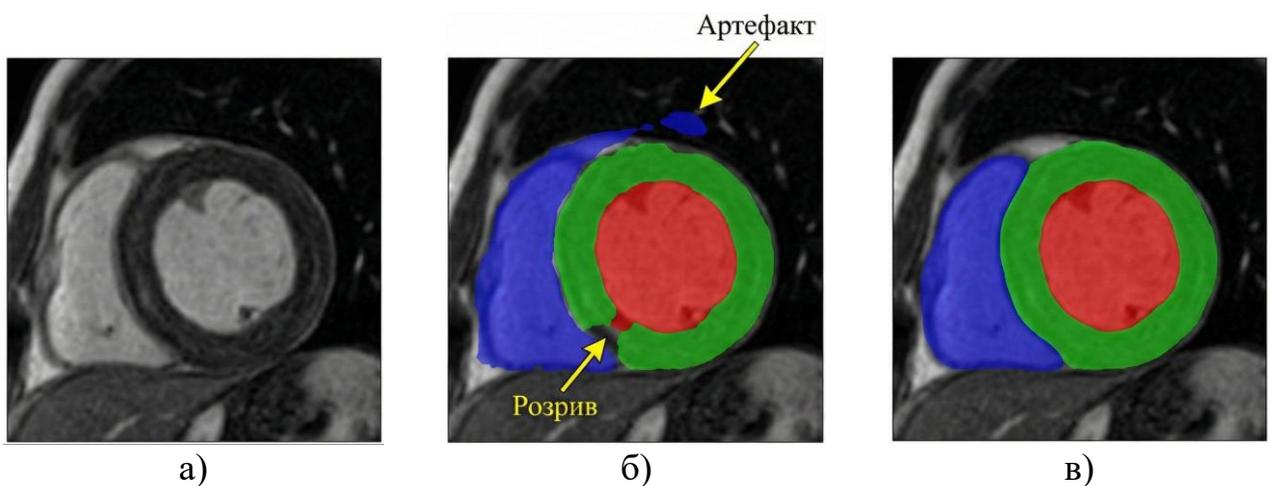


Рисунок 3.7 – Якісне порівняння результатів сегментації: а) оригінальне зображення, б) класична U-Net (помітні розриви в Міо та некоректна форма ПШ) та в) SKIF-Seg: відновлена цілісність кільця Міо та коректні межі шлуночків завдяки дії \mathcal{L}_{enc} та \mathcal{L}_{adj}

У підсумку, розроблений новий метод SKIF-Seg є вагомим кроком у напрямку створення надійних систем медичного діагностування, переходячи від статистичного опрацювання пікселів до навчання, що керується глибоким розумінням анатомічної структури. Перевагою методу є здатність гарантувати топологічну валідність масок сегментації: поєднання механізму EGA та обмежень ТААС дало можливість усунути суттєві для кардіології артефакти, такі як розриви Міо, суттєво знизивши метрику відстані Хаусдорфа та підвищивши клінічну довіру до результатів.

Проте аналіз запропонованого методу виявив кілька обмежень, які потребують уваги за практичного впровадження. Зокрема найбільшим викликом є висока чутливість процесу навчання до ініціалізації та налаштування гіперпараметрів функції втрат: балансування між п'ятьма компонентами цільової функції вимагає застосування складних стратегій, таких як «поступове прогрівання», що ускладнює швидку адаптацію методу до нових типів даних. Крім того, значні накладні витрати на обчислення карт SDF під час навчання підвищують вимоги до потужності обладнання, як от високопродуктивні графічні станції, що може стати бар'єром для використання в мобільних діагностичних комплексах без додаткової оптимізації. Також варто зазначити архітектурний ризик: у запропонованому каскадному підході точність кінцевого діагнозу жорстко залежить від якості сегментації, оскільки система не передбачає вбудованого механізму корекції помилок на етапі побудови графа.

Попри ці технічні компроміси, розроблений метод SKIF-Seg забезпечує високу анатомічну достовірність, яка є необхідною передумовою для переходу до наступного етапу – реляційного міркування та ідентифікації патологій, перетворюючи «чорну скриньку» нейронної мережі на більш прозорий та контрольований інструмент.

3.3. Метод ідентифікації патологій серця за зображенням МРТ з використанням графової згорткової мережі, орієнтованої на знання

У той час як сегментація надає кількісну інформацію про анатомію, кінцевою метою діагностичного комплексу є визначення патології (класифікація). Однак розгляд сегментації та класифікації як ізольованих етапів є спрощенням реального клінічного процесу. Лікар не ухвалює рішення виключно на основі контурів органів або ізольованих пікселів зображення. Його мислення є мультимодальним процесом, що поєднує візуальне сприйняття анатомії, розуміння фізіологічних взаємозв'язків та аналіз контексту.

З огляду на це, дисертаційна робота має на меті реалізувати підхід до підтримки прийняття клінічних рішень під назвою «цифровий двійник пацієнта». У межах цього підходу метод OPNI надає семантичний контекст, а метод SKIF-seg є генератором анатомічної структури. Запропонований у цьому підрозділі метод ідентифікації патологій серця за зображенням МРТ серця з використанням GCN (англ. «**K**nowledge-**I**nformed **G**raph **C**onvolutional **N**etwork», KI-GCN) забезпечує моделювання фізіологічних зв'язків та реляційне міркування.

Стандартні підходи до класифікації (наприклад, 3D-CNN) використовують глобальні ознаки зображення, часто ігноруючи складну систему взаємозв'язків між анатомічними структурами. Наприклад, діагноз «Гіпертрофічна кардіоміопатія» (HCM) ґрунтується не просто на локальному потовщенні Міо, а на специфічному співвідношенні товщини міжшлуночкової перегородки до задньої стінки ЛШ. Традиційним нейронним мережам важко «зрозуміти» такі реляційні концепції без явного моделювання структури об'єкта.

3.3.1 Формалізація задачі реляційної класифікації

Задачу класифікації можна формалізувати як відображення вхідних даних x у клас $y \in \mathcal{Y}$. У запропонованій методи вхідними даними x є структурований набір (тензор) анатомічних об'єктів (сегментів), що отримані на виході методу SKIF-Seg.

Важливою проблемою при побудові каскадних систем (сегментація \rightarrow граф \rightarrow класифікація) є ризик акумуляції помилки. Неточна сегментація на першому етапі, наприклад, розрив контуру ЛШ / ПШ або некоректне визначення об'єму ЛШ, автоматично стає спотвореним вхідним даним для класифікатора. Це створює точку відмови, де помилка нижнього рівня може призвести до хибного діагнозу.

Для вирішення цієї проблеми в роботі пропонується концепція «Стійкості до шуму» через використання графів знань. Серце пацієнта моделюється як граф $\mathcal{G} = (\mathcal{V}, \mathcal{E})$, де вузли \mathcal{V} відповідають анатомічним структурам (ЛШ, ПШ, сегменти Міо), а ребра \mathcal{E} кодують їхні просторові, функціональні та патофізіологічні зв'язки.

Гіпотеза полягає в тому, що GCN, яка використовує апріорну матрицю знань, здатна компенсувати дрібні помилки сегментації. Навіть якщо морфологічні параметри (наприклад, об'єм) виміряно з певною похибкою δ , наявність сильного зв'язку із симптоматикою та текстурними ознаками в графі дає змогу прийняти правильне діагностичне рішення. Граф працює як фільтр помилок нижнього рівня, стабілізуючи процес прийняття рішень.

Схема побудови графа пацієнта ілюстрована на рис. 3.8.

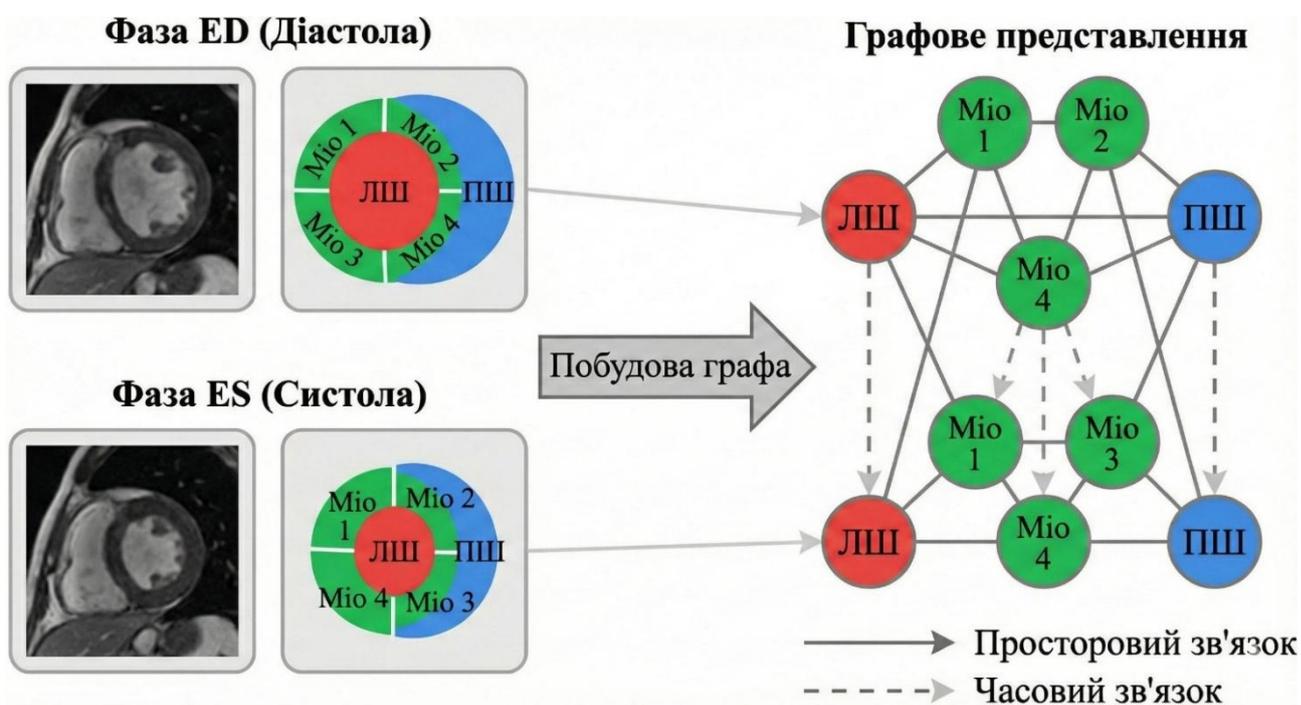


Рисунок 3.8 – Схема побудови графа пацієнта з масок сегментації; вузли представляють анатомічні регіони (ЛШ, ПШ, Mio), а ребра – просторові та часові (ED-ES) зв'язки

У роботі визначено множину вузлів $\mathcal{V} = \{v_1, \dots, v_N\}$, де кожен вузол відповідає певній анатомічній області. Для набору даних ACDC виділено 3 основні структури у 2 фазах серцевого циклу (ED – кінець діастоли та ES – кінець систоли), а також розділяємо Mio на 6 секторів за стандартом Американської асоціації серця, що дає змогу локалізувати патології.

3.3.2 Структура алгоритмічна реалізація методу ідентифікації патологій серця за зображенням МРТ серця

Розроблений новий метод KI-GCN поєднує три компоненти: гібридні вектори ознак, конструкцію графа на основі знань та механізм поширення повідомлень.

Спершу формалізуємо гібридні ознаки вузлів. На відміну від підходів, що використовують лише морфологію (рукотворні ознаки) або лише текстуру (приховані ознаки), метод KI-GCN реалізує гібридний підхід. Вектор ознак $h_v \in \mathbb{R}^D$ для кожного вузла $v \in \mathcal{V}$ є конкатенацією двох векторів (див. рис. 3.9):

$$h_v = [f_{\text{morph}}(v) \parallel f_{\text{deep}}(v)], \quad (3.11)$$

де $f_{\text{morph}}(v) \in \mathbb{R}^{d_m}$ – вектор морфологічних ознак, розрахованих явно на основі масок за методом SKIF-Seg (об'єм, площа, середня товщина, сферичність), а $f_{\text{deep}}(v) \in \mathbb{R}^{d_d}$ – вектор глибоких ознак, отриманий через проходження зони інтересу відповідної структури через попередньо навчену CNN (базова архітектура), наприклад, ResNet-18, з використанням операції ROI-Pooling.

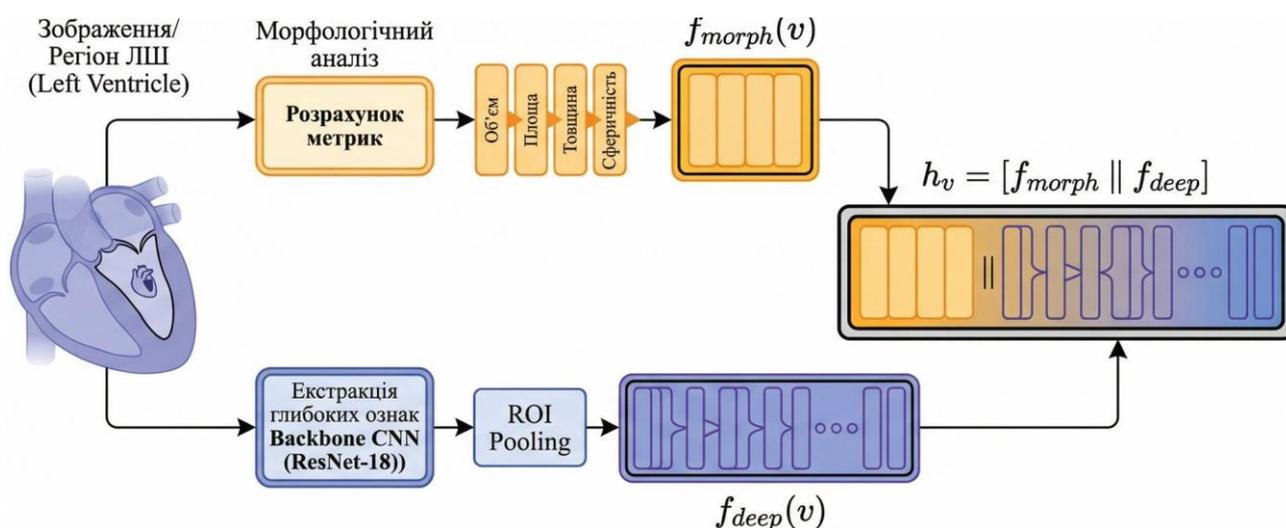


Рисунок 3.9 – Процес формування вектора ознак вузла h_v : об'єднання явно розрахованих морфологічних параметрів (об'єм, площа) та глибоких візуальних ознак, отриманих із базової архітектури CNN

Детальний склад ознак наведено в табл. 3.2.

Таблиця 3.2

Склад вектора ознак для вузлів графа в нейромережевій моделі за розробленим методом KI-GCN

Тип ознак	Компоненти
Морфологічні	Клінічно стандартні індекси (об'єми, фракція викиду, маса, товщина стінки), розраховані на основі масок за методом SKIF-Seg
Глибокі	Дескриптор, вилучений з «вузького місця» навченого енкодера за методом SKIF-Seg для кожної сегментованої структури

Такий підхід забезпечує резервування інформації: якщо сегментація неточна (помилка в f_{morph}), модель може покладатися на текстурні шаблони в f_{deep} , які менше залежать від точних меж контуру.

Опишемо процес побудови матриці суміжності на основі знань. Запропонований метод KI-GCN передбачає відмову від суто просторового визначення зв'язків, яке є стандартним для класичних GCN. Щоб модель могла враховувати геометричну близькість органів та значущість їхніх взаємодій, матрицю суміжності $\mathbf{A} \in \mathbb{R}^{N \times N}$ формалізовано як зважену суперпозицію двох структурних компонентів:

$$\mathbf{A} = \mathbf{A}_{\text{spatial}} + \gamma \cdot \mathbf{A}_{\text{knowledge}}, \quad (3.12)$$

де $\mathbf{A}_{\text{spatial}} \in \{0,1\}^{N \times N}$ – бінарна матриця просторової суміжності, елементи якої $a_{ij}^{\text{sp}} = 1$, якщо анатомічні структури (вузли) i та j мають спільну фізичну межу за результатами сегментації, і $a_{ij}^{\text{sp}} = 0$ в іншому випадку; $\mathbf{A}_{\text{knowledge}} \in \mathbb{R}^{N \times N}$ – матриця експертних діагностичних знань, елементи якої $a_{ij}^{\text{kn}} = w_{ij}$ відображають силу клінічного взаємозв'язку між структурами, де w_{ij} – вагові коефіцієнти, що визначаються на основі медичних настанов (наприклад, зв'язок між об'ємом ПШ

та товщиною перегородки при ARV); γ – фіксований гіперпараметр (коефіцієнт регуляризації знань), що визначає ступінь впливу експертної інформації на процес поширення повідомлень у графі.

У межах дослідження γ не є параметром, що навчається за допомогою зворотного поширення похибки. Це статичний коефіцієнт, значення якого встановлюється емпірично на етапі валідації моделі (для набору даних ACDC оптимальне значення склало $\gamma = 0.5$). Якщо $\gamma = 0$, модель вироджується в стандартну GCN, що враховує лише анатомічне сусідство. Збільшення γ дає змогу моделі «ігнорувати» дрібні помилки сегментації (шум у $\mathbf{A}_{\text{spatial}}$), спираючись на верифіковані медичні закономірності у $\mathbf{A}_{\text{knowledge}}$.

Варто зазначити, що матриця $\mathbf{A}_{\text{knowledge}}$ на даному етапі будується на основі ручного аналізу медичних настанов. Наприклад, для виявлення аритмогенної дисплазії ПШ (ARV) є важливим зв'язок між об'ємом ПШ та станом Міо, тому вага цього ребра штучно збільшується ($w_{ij} > 1$). Хоча ручне конструювання є суб'єктивним та трудомістким процесом, воно забезпечує впровадження верифікованих експертних знань, що є актуальним та виправданим для задач із малою кількістю даних. У перспективі цей процес може бути автоматизовано за допомогою методів NLP, що розглянуті в розділі 2, для вилучення зв'язків безпосередньо з медичної літератури. Ілюстрація формування матриці суміжності наведена на рис. 3.10.

Подамо механізм поширення повідомлень та класифікацію. Для агрегації інформації використано спектральну графову згортку за Кіпфом та Веллінгом (див. рис. 3.11). Правило оновлення ознак вузлів на шарі $l + 1$ формалізовано так:

$$H^{(l+1)} = \sigma \left(D^{-\frac{1}{2}} A D^{-\frac{1}{2}} H^{(l)} \Theta^{(l)} \right), \quad (3.13)$$

де $A = \mathbf{A} + I_N$ (матриця з петлями самозв'язку), D – діагональна матриця ступенів вузлів ($D_{ij} = \sum_j A_{ij}$), $H^{(l)}$ – матриця ознак усіх вузлів на шарі l , $\Theta^{(l)}$ – матриця ваг, що навчаються, σ – функція активації (ReLU).

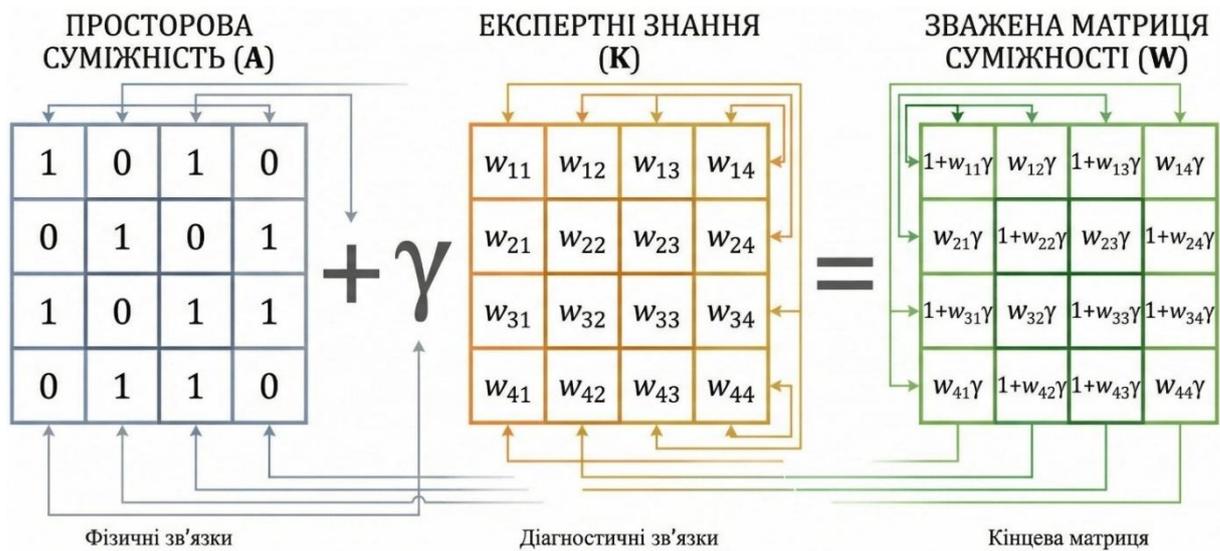


Рисунок 3.10 – Ілюстрація формування матриці суміжності A як комбінації просторових зв'язків та експертних знань $A_{\text{knowledge}}$

Ця операція фактично реалізує обмін інформацією між анатомічними структурами. Вузол «Лівий шлуночок» оновлює свій стан, отримуючи інформацію від вузла «Міокард» та «Правий шлуночок», враховуючи силу зв'язку, визначену в матриці A .

Після l шарів GCN отримано матрицю збагачених ознак $H^{(l)}$. Для агрегації вузлових ознак у єдиний вектор-дескриптор пацієнта h_{graph} та забезпечення інтерпретованості рішень уперше в контексті серцевих графів застосовано механізм глобальної субдискретизації з увагою (англ. «Global Attention Pooling, GAP):

$$\alpha = \text{Softmax}\left(w_{\text{gate}}^T \tanh\left(W_{\text{gate}} H^{(L)T}\right)\right), \quad (3.14)$$

$$h_{\text{graph}} = \sum_{i=1}^N \alpha_i h_i^{(L)}, \quad (3.15)$$

де α_i – вага важливості i -го вузла (анатомічної структури) для прийняття рішення.

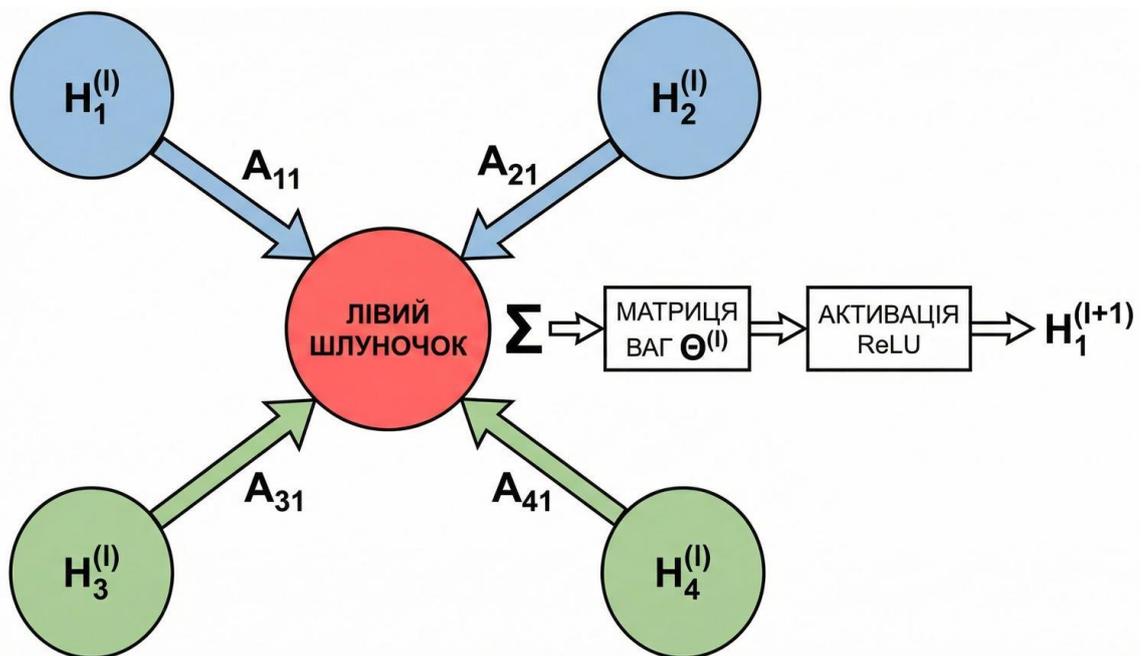


Рисунок 3.11 – Схематичне зображення операції графової згортки: агрегація інформації від сусідніх вузлів (анатомічних структур) для оновлення представлення поточного вузла

Механізм субдискретизації, що формалізований за формулами (3.14)–(3.15), дає змогу моделі динамічно фокусуватися, наприклад, на ПШ при підозрі на ARV або на ЛШ при підозрі на DCM, ігноруючи нерелевантні структури.

Фінальна класифікація здійснюється через БШП:

$$Y_{\text{pred}} = \text{Softmax}(\text{БШП}(h_{\text{graph}})). \quad (3.16)$$

Навчання моделі відбувається внаслідок мінімізації функції втрат, яка включає перехресну ентропію та регуляризацію ваг уваги для забезпечення розрідженості (L1-norm на α), щоби підвищити інтерпретованість:

$$\mathcal{L}_{\text{class}} = - \sum_{c=1}^{N_{\text{classes}}} (Y_{\text{true},c} \log(Y_{\text{pred},c})). \quad (3.17)$$

Ваги компонентів функції втрат, що визначають баланс між точністю та відповідністю апріорним знанням, наведено в табл. 3.3.

Таблиця 3.3

Вагові коефіцієнти компонентів функції втрат для навчання моделі класифікації

Компонент втрат	Вага
Dice, w_D	1,0
Cross-entropy, w_{CE}	0,5
Топологічні обмеження, $\lambda_{ТААС}$	0,1

Далі подамо покрокове виконання запропонованого методу.

Вхідними даними методу є множина пацієнтів \mathcal{P} та база експертних знань \mathcal{K}_{rules} .

Крок 1. Підготовка графів для кожного пацієнта $p \in \mathcal{P}$ виконується так:

- 1) виконати сегментацію вхідного зображення нейромережевою моделлю за методом SKIF-Seg (результат – маска M);
- 2) розрахувати вектор явних морфологічних ознак f_{morph} (об'єми, площі);
- 3) вилучити вектор глибоких ознак f_{deep} з проміжного шару базової архітектури CNN;
- 4) сформувати початкову матрицю ознак $H^{(0)}$ внаслідок конкатенації f_{morph} та f_{deep} ;
- 5) побудувати матрицю суміжності A як суперпозицію просторових зв'язків та зважених ребер із бази знань \mathcal{K}_{rules} .

Крок 2. Ітеративне навчання GCN:

- 1) виконати пряме поширення сигналу через шари графової згортки за формулою (3.13);
- 2) розрахувати ваги уваги α та глобальний дескриптор графа h_{graph} за формулами (3.14)–(3.15);
- 3) отримати вектор ймовірностей діагнозів Y_{pred} ;
- 4) обчислити функцію втрат \mathcal{L}_{class} та виконати зворотне поширення помилки для оновлення ваг Θ .

Вихідними даними методу є 1) навчена нейромережева модель класифікації за методом KI-GCN, що здатна до реляційного міркування та 2) набір ваг уваги α для інтерпретації рішень.

3.3.3 Експериментальна валідація, аналіз стійкості до збурень та інтерпретованість

Запропонований метод KI-GCN та навчена за ним нейромережева модель класифікації провалідовані для задачі класифікації 5 патологій серця (NOR, MINF, DCM, HCM, ARV) за зображенням МРТ серця на еталонному наборі даних ACDC.

Варто зауважити, що набір ACDC містить лише 100 пацієнтів (по 20 на клас), що є вкрай малою вибіркою для навчання глибоких нейронних мереж від початку. Однак саме тут проявляється перевага графового підходу. Структура графа вносить сильне індуктивне зміщення, суттєво звужуючи простір пошуку рішень порівняно з повнозв'язними або згортковими мережами, яким потрібно самостійно «відкривати» структуру даних. Це дає змогу нейромережевій моделі класифікації навчатися навіть на обмежених вибірках без суттєвого перенавчання, що підтверджується використанням суворої 5-кратної перехресної валідації.

Запропонований метод KI-GCN порівняно з такими аналогами:

1) 3D ResNet-подібна мережа, що працює безпосередньо з вокселями зображення;

2) метод опорних векторів (англ. «Support Vector Machine», SVM), навчений виключно на морфологічних ознаках (об'єми, фракція викиду).

3) GCN із матрицею суміжності, заснованою лише на просторовому сусідстві (без $A_{\text{knowledge}}$).

Результати класифікації подано в табл. 3.4.

Модель класифікації за методом KI-GCN демонструє кращі результати (Accuracy – 94,0 %), перевершуючи як підхід «чорної скриньки» (CNN, 85,0 %), так і класичний морфологічний аналіз (88,5 %).

Таблиця 3.4

Порівняння результатів класифікації захворювань серця на валідаційному наборі ACDC (5-кратна перехресна перевірка); символ \pm позначає стандартне відхилення; більші значення відповідають кращим показникам

Модель	Accuracy	Precision	Recall	F ₁ -macro	AUC-ROC
Базова CNN (3D ResNet)	0,85 \pm 0,04	0,85 \pm 0,04	0,84 \pm 0,05	0,84 \pm 0,04	0,92 \pm 0,03
Базова морфологія (SVM)	0,89 \pm 0,03	0,89 \pm 0,03	0,88 \pm 0,04	0,88 \pm 0,03	0,94 \pm 0,02
Класична GCN	0,91 \pm 0,03	0,91 \pm 0,03	0,90 \pm 0,03	0,90 \pm 0,03	0,95 \pm 0,02
KI-GCN (запроп.)	0,94 \pm 0,02	0,94 \pm 0,02	0,94 \pm 0,02	0,94 \pm 0,02	0,97 \pm 0,01

Такий результат свідчить про те, що комбінація візуальних шаблонів, як от текстура тканини, видима на МРТ тощо, та чітких метрик у структурованому графі забезпечує повнішу діагностичну картину. Важливо відзначити, що введення матриці знань $A_{\text{knowledge}}$ (порівняння класичної GCN проти KI-GCN) забезпечило приріст точності в 3,5%, що підтверджує важливість явного моделювання діагностичних кореляцій для підвищення результативності всієї системи.

Одним із ризиків каскадної архітектури є поширення помилок сегментації. Щоби перевірити гіпотезу про те, що граф працює як фільтр помилок, у межах дослідження проведено додатковий аналіз чутливості. Штучний шум внесено у вхідні морфологічні параметри f_{morph} (наприклад, симулюючи похибку вимірювання об'єму ЛШ до $\pm 10\%$). Результати показали, що точність методу SVM падає лінійно зі зростанням шуму. Натомість точність моделі за методом KI-GCN залишається стабільною (падіння $< 2\%$ при шумі 5%). Це пояснюється тим, що граф спирається не тільки на одне значення, а й на сукупність зв'язків та глибокі

текстурні ознаки (f_{deep}), які залишаються незмінними. Наявність сильних ребер у $A_{\text{knowledge}}$ дає змогу моделі «відновлювати» правильний контекст навіть при локальних неточностях вхідних даних.

Аналіз ваг уваги α (GAP weights), що проілюстрований на рис. 3.12, виявив певні закономірності:

- для пацієнтів з ARV (аритмогенна дисплазія ПШ) вага вузла «Правий шлуночок» була в середньому у 2.5 рази вищою, ніж в інших класів;
- для пацієнтів з HCM (гіпертрофічна кардіоміопатія) максимальні ваги стабільно отримували сегменти міжшлуночкової перегородки.

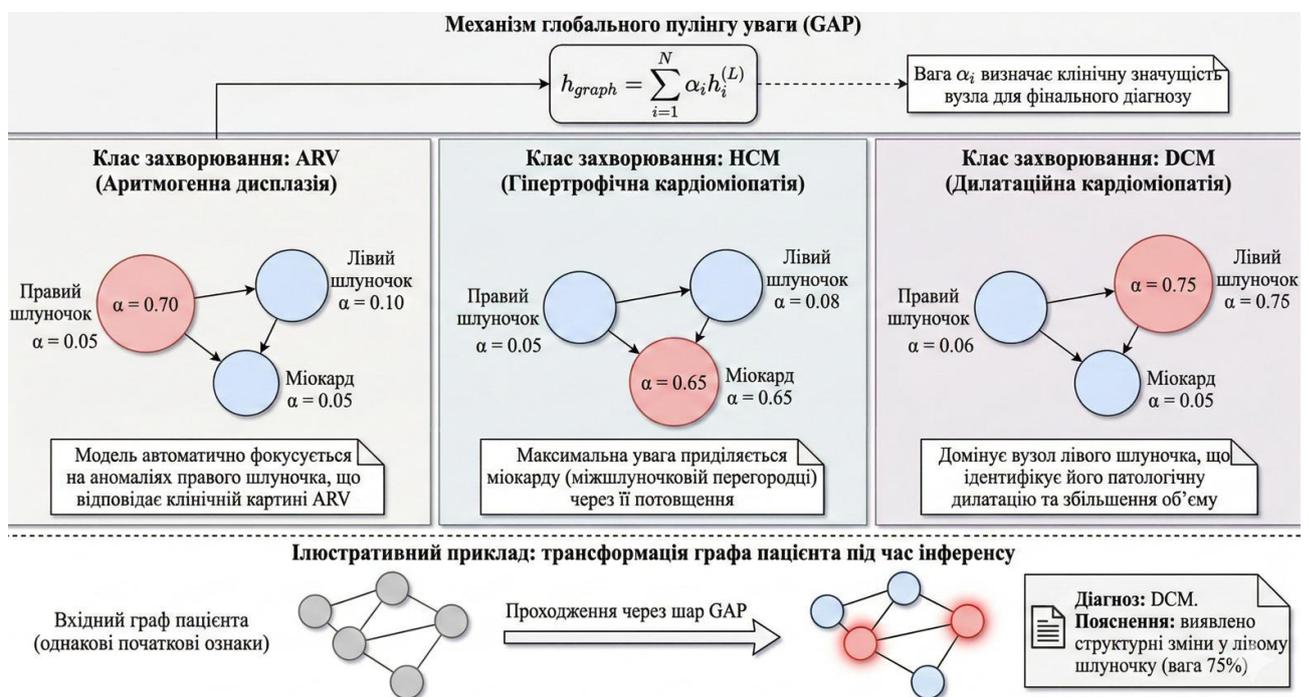


Рисунок 3.12 – Інтерпретація ваг уваги α (GAP weights) для різних класів захворювань; наприклад, для ARV (аномалії ПШ) модель автоматично призначає найбільшу вагу вузла «Правий шлуночок»

Подібний підхід підтверджує, що модель не просто вивчила статистичні кореляції, а «зрозуміла» клінічну суть патологій, що робить її рішення прозорими та переконливими для лікаря-діагноста.

Узагальнюючи результати розроблення та валідації методу KI-GCN, варто відзначити, що запропонований підхід забезпечує якісний перехід від абстрактного

розпізнавання образів до структурно-орієнтованого міркування. Перевагою методу є здатність моделі ідентифікації явно оперувати анатомічними взаємозв'язками, закодованими в матриці суміжності, замість покладання виключно на латентні статистичні кореляції піксельного простору. Результати експериментів підтвердили, що інтеграція апріорних знань дає змогу досягти високих показників точності класифікації та забезпечити прозору інтерпретованість рішень через механізм глобальної субдискретизації, що важливо для верифікації логіки роботи алгоритму лікарем. Цінною характеристикою методу є стійкість GCN до стохастичного шуму у вхідних морфологічних даних, що дає можливість методу діяти як фільтр похибок попереднього етапу опрацювання, стабілізуючи процес виявлення патологій.

Проте проведений аналіз виявив об'єктивні обмеження запропонованого методу, які необхідно враховувати. Недоліком залишається архітектурна залежність від результативності етапу сегментації: хоча граф стійкий до варіативності метричних параметрів, грубі структурні помилки, такі як повна відсутність вузла внаслідок збою сегментації, порушують топологію графа пацієнта, що може призвести до некоректної класифікації. Окрім цього, процедура формування матриці діагностичних кореляцій потребує ручного аналізу та формалізації медичних настанов, що є трудомістким процесом і ускладнює автоматичне масштабування підходу на нові нозологічні одиниці без залучення профільних експертів. Попри окреслені виклики, запропонований метод KI-GCN демонструє перспективність застосування гібридних нейро-символьних систем.

3.4. Висновки до розділу 3

У третьому розділі подано розгорнутий опис розробленого нового методу сегментації SKIF-Seg. Структура методу ґрунтується на синергетичному поєднанні механізму EGA та складеної функції втрат ТААС. Цей підхід відрізняється від стандартних нейромереж тим, що застосовує математичний апарат SDF замість виключно попівсельної оптимізації. Це дає змогу алгоритмічно забезпечувати

анатомічну коректність просторових результатів, дотримуючись умов вкладеності та суміжності структур серця. Як наслідок, метод мінімізує появу топологічних артефактів, зокрема розривів контурів чи ізольованих хибних ділянок, і суттєво підвищує точність ідентифікації меж внутрішніх органів.

Також у розділі наведено опис розробленого нового методу ідентифікації патологій KI-GCN, який впроваджує парадигму реляційного міркування на основі GCN. Метод формує графи, де вузли містять гібридні морфологічні та глибокі візуальні ознаки, а ребра кодують просторові та верифіковані діагностичні закономірності. У межах методу вперше адаптовано механізм GAP для контексту серцевих графів. Таке архітектурне рішення забезпечує прозору клінічну інтерпретованість рішень, даючи змогу кількісно оцінити ваговий внесок кожного анатомічного сегмента у формування підсумкового діагнозу.

Для програмної реалізації цих методів розроблено відповідний математичний апарат. Він включає модулі попереднього опрацювання медичних даних, динамічної генерації просторових карт відстаней та оптимізації графових мереж. Запропоновані гібридні моделі демонструють високу точність сегментації та класифікації, а також стійкість обчислень, що є базовою умовою для їхнього безпечного впровадження в сучасну медичну практику.

Основні результати розділу опубліковані у працях [25, 28, 30, 32].

РОЗДІЛ 4.

ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ТА ВЕРИФІКАЦІЯ МЕТОДІВ ІНТЕГРАЦІЇ ЗНАНЬ У МЕДИЧНІ ДІАГНОСТИЧНІ СИСТЕМИ

У четвертому розділі наведено розгорнутий опис програмної реалізації розроблених компонентів інтелектуальної інформаційної системи, які об'єднані в єдиний апаратно-програмний комплекс під назвою «IDK Medical AI». Зазначений програмний комплекс реалізовано на основі розроблених методів, запропонованих у попередніх розділах дисертаційної роботи, а також із дотриманням принципів модульної архітектури програмного забезпечення, з огляду на мікросервісну взаємодію компонентів. Розроблена система забезпечує масштабове опрацювання гетерогенних медичних даних, формуючи послідовне опрацювання даних, що включає алгоритми сегментації медичних зображень, класифікації патологічних станів на основі графових структур та семантичного аналізу текстових клінічних записів природною мовою. Для забезпечення взаємодії медичного персоналу та інженерів-дослідників із системою реалізовано графічний програмний інтерфейс користувача (візуальні форми якого винесено в додатки до дисертаційної роботи). Цей інтерфейс формалізує процеси завантаження наборів даних, налаштування гіперпараметрів нейромережових моделей та візуалізації результатів діагностування у вигляді двовимірних і тривимірних проєкцій із відповідними статистичними звітами.

У цьому розділі також подано результати комплексних експериментальних досліджень, основною метою яких було емпіричне підтвердження результативності запропонованих методів на репрезентативних клінічних наборах даних відкритого доступу, зокрема MIMIC-CXR, ACDC, M&Ms-2 та MedNLI. Процес валідації методу адаптивної дистиляції знань показав підвищення значень метрик якості під час процесу адаптації нейромережових моделей до нових типів медичних діагностичних комплексів. Заразом, експериментальне дослідження розробленого методу SKIF-Seg продемонструвало покращення значень DSC та

зниження показників метрики відстані Хаусдорфа, що стало можливим завдяки впровадженню математичних топологічних обмежень до цільової функції втрат.

Розділ завершується порівняльним аналізом розроблених алгоритмічних рішень із сучасними світовими аналогами (включно з великими мовними моделями архітектури Трансформер), а також дослідженням обчислювальної складності розроблених алгоритмів. Отримані емпіричні дані підтверджують гіпотезу про те, що запропоновані методи не лише сприяють підвищенню точності автоматизованого аналізу, але й забезпечують стабільність роботи нейронних мереж, їхню стійкість до збурень вхідних даних та загальну інтерпретованість результатів у середовищі лікувальних закладів.

4.1. Архітектура програмного комплексу та методологія експерименту

У межах проведеного дослідження експериментальне тестування розроблених методів та математичних моделей передбачало формування спеціалізованого програмного середовища. Основними критеріями до такого середовища були:

- забезпечення гнучкості під час конструювання обчислювальних графів;
- стабільна робота з гетерогенними форматами даних, як от зображення різних модальностей, неструктурований текст природною мовою, графи знань тощо;
- забезпечення повної відтворюваності отриманих експериментальних результатів.

З огляду на вказані вище вимоги, у дисертаційній роботі спроектовано та реалізовано програмний комплекс «IDK Medical AI». Створений програмний комплекс розміщений в публічному репозиторії на платформі GitHub [142] (див. додаток В). Візуальні екранні копії графічного інтерфейсу користувача розробленого програмного комплексу «IDK Medical AI» наведено в додатку Г.

4.1.1 Концептуальна архітектура експериментальної системи

Розроблений програмний комплекс функціонує на основі принципів мікросервісної архітектури. Такий підхід дає змогу на рівні операційної системи ізолювати логіку попереднього опрацювання даних від процесів ітеративного навчання глибоких моделей та модулів статистичного оцінювання результатів. Система організована як сукупність слабозв'язаних компонентів, що взаємодіють через стандартизовані програмні інтерфейси в середовищі високопродуктивних обчислень. На рис. 4.1 наведено спрощену загальну схему архітектури розробленої інтелектуальної інформаційної системи.

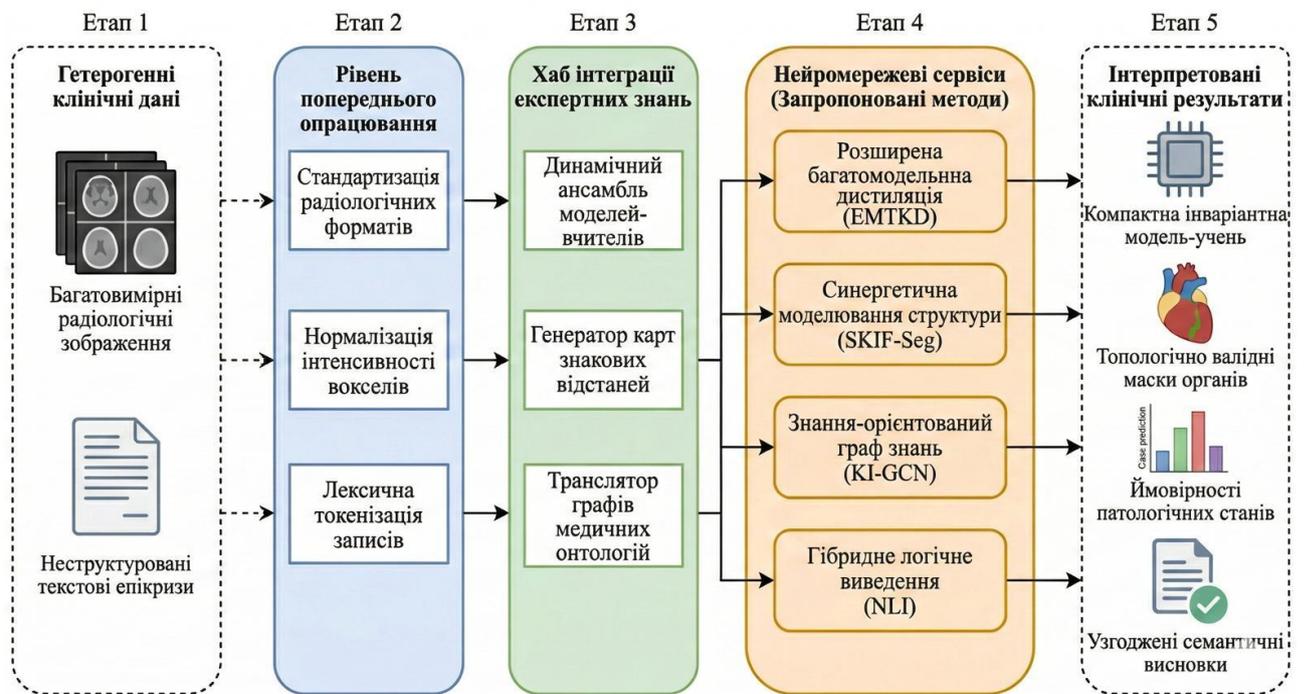


Рисунок 4.1 – Блок-схема архітектури інтелектуальної інформаційної системи інтеграції знань програмного комплексу «IDK Medical AI»

Важливим структурним елементом розробленої програмної архітектури є рівень абстракції даних. У клінічній практиці дані генеруються у вузькоспеціалізованих медичних форматах. Наприклад, радіологічні зображення зберігаються у форматі DICOM, що містить як піксельні масиви даних, так і метадані пацієнта, тоді як текстові медичні записи найчастіше передаються через

протоколи HL7 або FHIR. Ця гетерогенність об'єктивно ускладнює безпосереднє використання даних у тензорних обробленнях нейронних мереж. Розроблений модуль абстракції реалізує програмний шаблон проектування «Стратегія» для уніфікації програмного інтерфейсу доступу. Формально процес підготовки тензора даних X_{tensor} із початкового джерела S_{raw} описано як композицію функцій попереднього опрацювання Φ_{prep} та функції аугментації Φ_{aug} :

$$X_{\text{tensor}} = \Phi_{\text{aug}} \left(\Phi_{\text{prep}} \left(S_{\text{raw}}; \theta_{\text{norm}} \right); \theta_{\text{stoch}} \right), \quad (4.1)$$

де параметр θ_{norm} позначає параметри детермінованої нормалізації (приведення значень інтенсивності пікселів зображень магнітно-резонансної томографії до діапазону одиничного нормального розподілу або застосування алгоритму Z-score нормалізації), параметр θ_{stoch} визначає налаштування стохастичних перетворень (випадкові афінні обертаня матриць зображень, застосування еластичних деформацій або додавання адитивного шуму Гауса).

Зазначені стохастичні перетворення використовуються виключно на етапі навчання нейромережових моделей для їхньої регуляризації та запобігання перенавчанню. Для ілюстрації алгоритмічних принципів роботи системи в цьому підрозділі подано концептуальні структурні схеми та блок-схеми.

На рис. 4.2 проілюстровано концептуальну структурну схему головного модуля управління та маршрутизації системи «IDK Medical AI». На рис. 4.3 наведено блок-схему модуля імпорту та анонімізації даних формату DICOM.

Наступним рівнем системи є обчислювальне ядро, архітектура якого базується на використанні тензорного фреймворку PyTorch. Даний рівень відповідає за динамічну побудову графів обчислень. Цей аспект є важливим для коректної реалізації запропонованих у роботі математичних методів, оскільки вони містять умовні переходи (зокрема, у механізмах просторової експертної уваги) та потребують виконання диференційовних операцій над графовими топологіями. Процес оптимізації абстрактної моделі M з набором вагових параметрів W

формалізується як ітеративна мінімізація емпіричного ризику \mathcal{R}_{emp} на просторі навчальної вибірки D_{train} :

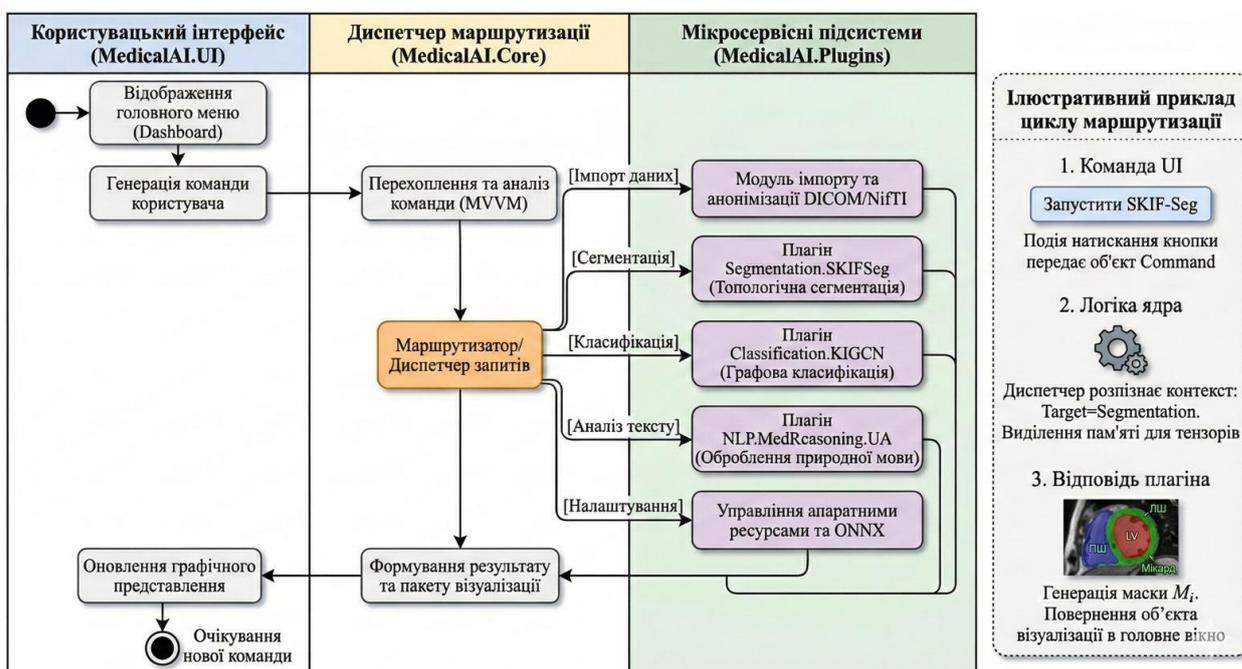


Рисунок 4.2 – Блок-схема головного модуля управління та маршрутизації системи «IDK Medical AI», що забезпечує доступ до підсистем завантаження даних, сегментації, класифікації та налаштувань

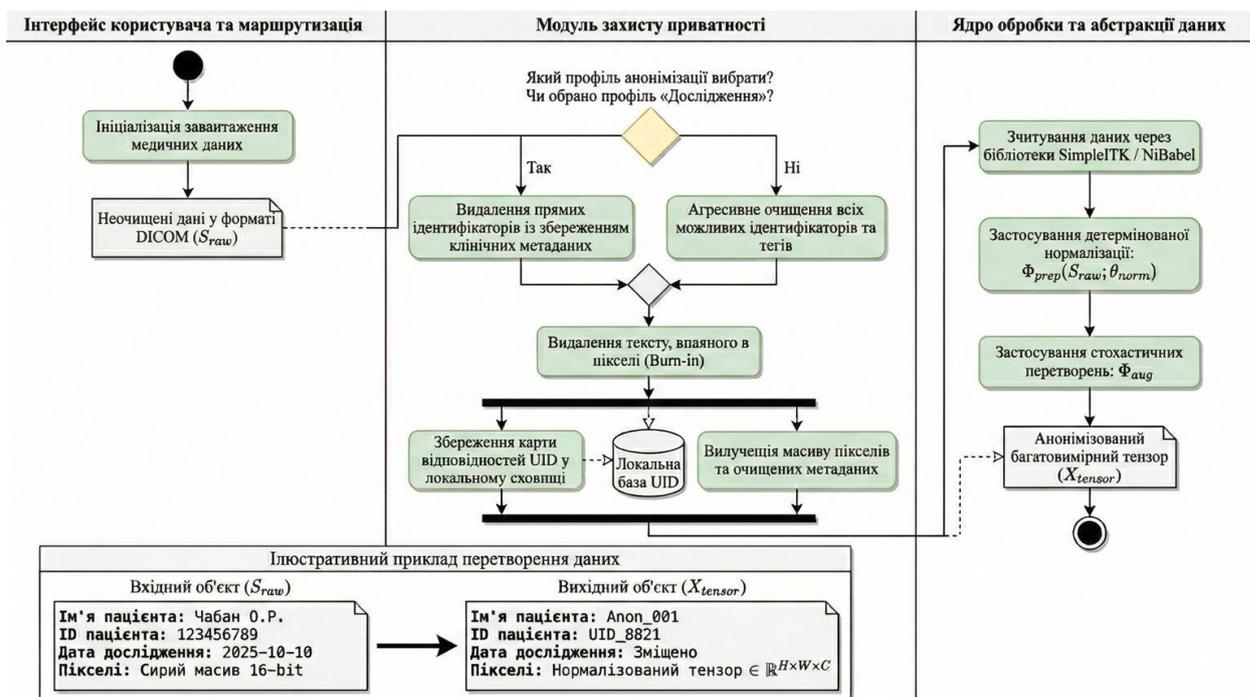


Рисунок 4.3 – Блок-схема модуля імпорту та анонімізації даних формату DICOM, що формалізує процес застосування профілів захисту приватності

$$W^* = \arg \min_W \left(\frac{1}{|\mathcal{D}_{\text{train}}|} \sum_{(x,y) \in \mathcal{D}_{\text{train}}} \mathcal{L}(\mathcal{M}(x;W), y) + \lambda \Omega(W) \right), \quad (4.2)$$

де функція \mathcal{L} – це складена цільова функція втрат, яка, залежно від конфігурації моделі, може включати компоненти інтеграції знань (топологічні втрати, сформовані на основі карт знакових відстаней, або дивергенцію для забезпечення дистилляції знань), $\Omega(W)$ – член регуляризації вагових коефіцієнтів (у більшості експериментів використовувалася L_2 -норма), а λ – скалярний коефіцієнт, що визначає силу застосованої регуляризації.

На рис. 4.4 подано блок-схему запуску модуля сегментації зображень МРТ серця за методом SKIF-Seg.

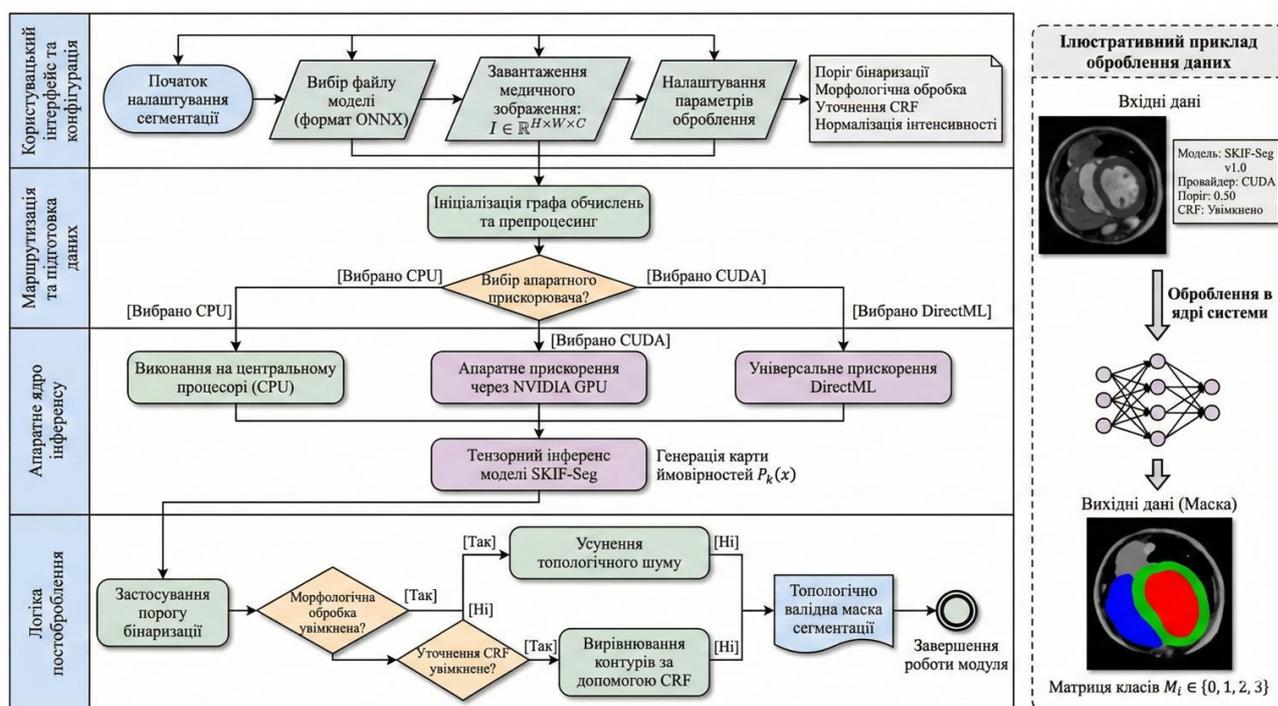


Рисунок 4.4 – Блок-схема запуску модуля сегментації за методом SKIF-Seg, що ілюструє потік даних від вибору моделі та параметрів оброблення даних до апаратного прискорювача

На рис. 4.5 проілюстровано блок-схему підсистеми розподілу обчислювальних ресурсів програмного комплексу «IDK Medical AI».

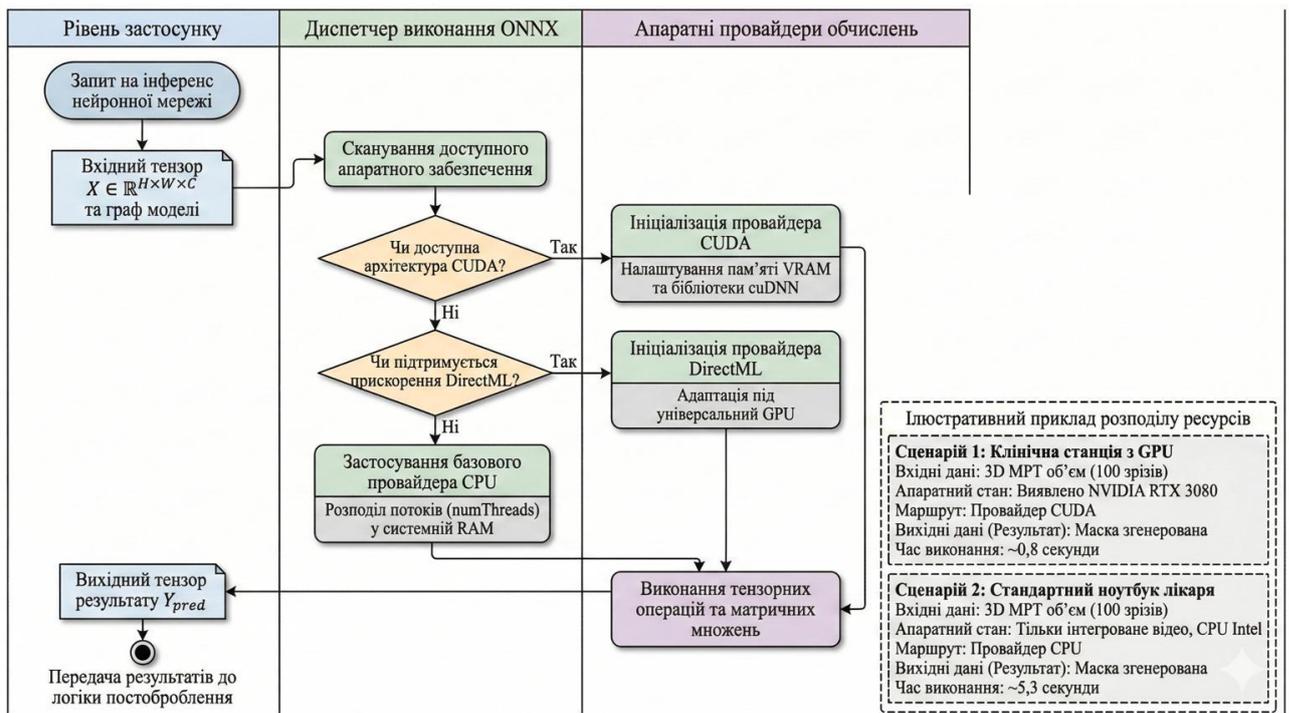


Рисунок 4.5 – Блок-схема підсистеми розподілу обчислювальних ресурсів, що забезпечує крос-платформену сумісність через динамічний вибір провайдерів (CPU, CUDA, DirectML)

Третім функціональним рівнем є спеціалізований модуль інтеграції знань. Його призначення полягає в забезпеченні безперервного обміну даними між багатoshаровими нейронними мережами та зовнішніми базами структурованих знань. Зазначений модуль містить програмні адаптери для підключення до UMLS з використанням інструментарію MetaMap API. Також він включає математичні генератори карт SDF для реалізації топологічних обмежень та алгоритми нелінійної агрегації для ансамблевих методів дистиляції. Для забезпечення інтеграції знань з онтологічної бази модуль трансформує дискретні символічні концепти C_{umls} у неперервні вектори вбудовування v_{emb} за допомогою попередньо оптимізованої моделі графових вбудовувань f_{KGE} :

$$v_{\text{emb}} = f_{\text{KGE}}(C_{\text{umls}}; \Theta_{\text{graph}}), \quad (4.3)$$

де Θ_{graph} позначає набір параметрів моделі GCN, зокрема, матриці вбудовувань сутностей та матриці відношень, які були оптимізовані з використанням MultE.

Насамкінець, «IDK Medical AI» має підмодуль автоматизованого звітування, що призначений для збереження візуальних артефактів та обрахованих метрик (див. рис. 4.6).

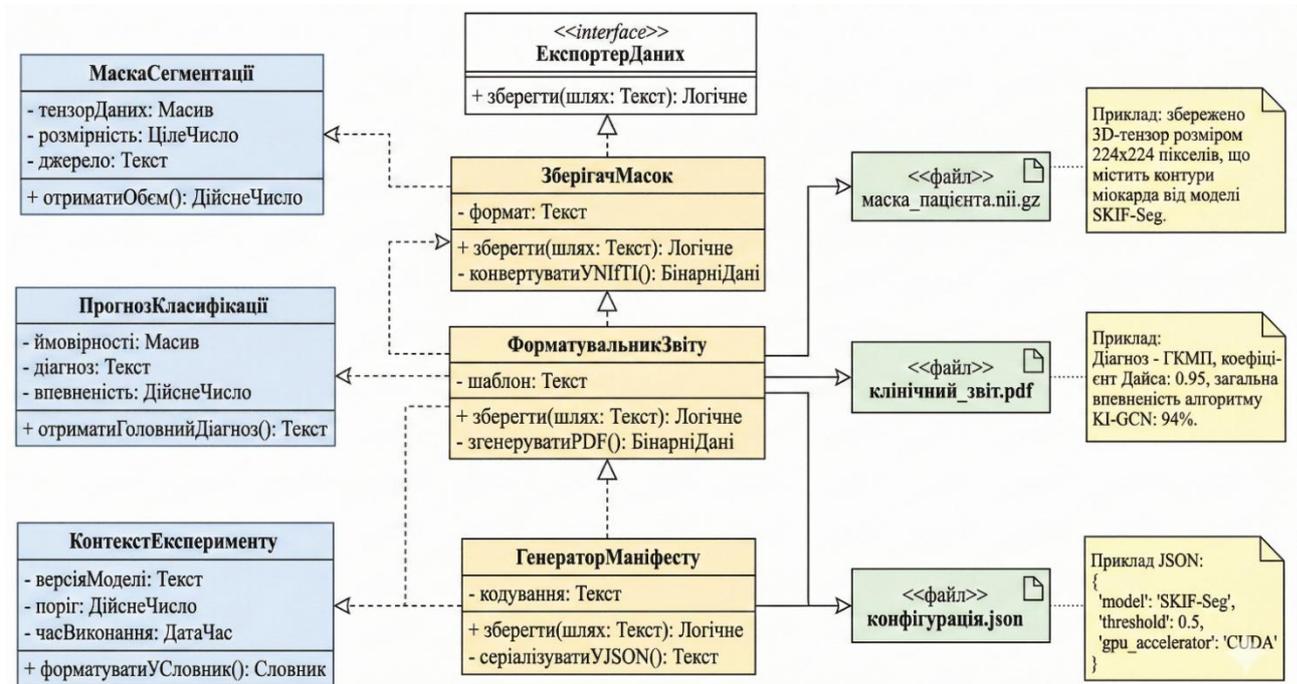


Рисунок 4.6 – Блок-схема модуля експорту та комплексного звітування системи «IDK Medical AI», що дає змогу зберігати діагностичні результати, JSON-маніфести конфігурацій експериментів та згенеровані маски

4.1.2 Технічні деталі реалізації та середовище виконання

Для забезпечення продуктивності обчислень та відтворюваності експериментальних результатів розроблення програмного забезпечення велася з використанням технологічного стека, наведеного в табл. 4.1.

Використання фреймворку PyTorch обґрунтовано його здатністю до побудови динамічних графів обчислень за принципом «define-by-run». Цей принцип дав можливість спростити імплементацію нестандартних диференційовних шарів, як от запропонований механізм EGA та шари графових згорток.

Таблиця 4.1

Апаратне та програмне забезпечення, використане для реалізації та тестування системи «IDK Medical AI»

Компонент системи	Характеристика / Версія	Призначення в експерименті
Апаратне забезпечення		
Процесор (CPU)	1 × i9-13900K (36M Cache, 3.20 GHz)	Багатопотокове попереднє опрацювання даних, генерація SDF
Графічний прискорювач (GPU)	1 × NVIDIA GPU RTX 3080 (10 GB VRAM)	Паралельне навчання ансамблів глибоких мереж та розрахунок графів
Оперативна пам'ять	64 GB ECC DDR4	Кешування медичних зображень у форматі NIfTI
Програмне забезпечення		
Операційна система	Ubuntu 22.04 LTS	Основне середовище виконання
Мова програмування	Python 3.10.8	Написання алгоритмічної логіки
Фреймворк глибокого навчання	PyTorch 2.1.0 + cuDNN 8.9	Побудова та навчання нейронних мереж
Обробка медичних зображень	SimpleITK 2.3.0, NiBabel 5.1.0	Читання, конвертація та геометричні перетворення зображень MPT

Опрацювання багатовимірних тензорних даних здійснювалося за допомогою оптимізованої математичної бібліотеки NumPy. Зчитування специфічних радіологічних форматів (NIfTI та DICOM) забезпечувалося бібліотеками SimpleITK та NiBabel. Специфічні геометричні перетворення, зокрема алгоритм розрахунку точних EDT, що використовується у функції втрат ТААС, були впроваджені з використанням оптимізованих процедур мовою C, доступних через бібліотеку SciPy (функція `scipy.ndimage.distance_transform_edt`). Це дало змогу підтримувати необхідну швидкість обчислень топологічних обмежень на етапі

прямого поширення сигналу під час градієнтного спуску без зниження загальної продуктивності навчання.

Розпаралелення матричних обчислень забезпечувалося архітектурою CUDA версії 12.x та бібліотекою cuDNN, що спеціалізується на оптимізації примітивів глибоких нейронних мереж. Ці технології дали змогу прискорити операції тривимірної згортки та множення розріджених матриць, характерних для GCN. Процес моніторингу метрик у реальному часі, керування конфігураціями експериментів та версіонування збережених вагових коефіцієнтів моделей здійснювався за допомогою платформи Weights & Biases (WandB).

Завершальним компонентом програмної архітектури є підсистема статистичного оцінювання та візуалізації. Її призначення полягає в автоматизованому розрахунку загальноприйнятих метрик точності (DSC, відстань Хаусдорфа, площа під ROC-кривою) та виконанні статистичних тестів для перевірки значущості відмінностей між моделями (зокрема, використання t-критерію Стьюдента для незалежних вибірок та U-критерію Вілкоксона). Перелік та формалізований опис застосованих метрик наведено в табл. 4.2.

4.2. Експериментальне дослідження методу адаптивної дистиляції знань від моделей-вчителів до моделі-учня

Першим етапом емпіричної валідації стала перевірка результативності удосконаленого ЕМТКД, що призначений для розв'язання задачі адаптації домену для класифікації медичних зображень. Проблема доменного зсуву виникає в ситуаціях, коли нейромережева модель, параметри якої оптимізовані на наборі даних одного медичного закладу (початковий домен), демонструє зниження діагностичної точності під час інференсу на даних іншої установи (цільовий домен). Цей ефект зумовлений відмінностями у фізичних параметрах сканерів, локальних протоколах візуалізації та демографічних характеристиках популяції пацієнтів.

Статистичні критерії та метрики оцінювання, застосовані для валідації
розроблених методів

Метрика / Критерій	Формула / Опис	Цільове застосування
DSC	$DSC = \frac{2 P \cap G }{ P + G }$	Оцінювання точності перекриття сегментації, P – прогноз, G – істина
Відстань Хаусдорфа 95 % (HD95)	95-й перцентиль найкоротших відстаней між межами	Оцінювання точності меж органів та чутливості до топологічних викидів
Area Under the Curve-Receiver Operating Characteristic (AUC-ROC)	Площа під кривою	Оцінювання якості класифікації патологій в умовах дисбалансу класів
F ₁ -macro	Гармонійне середнє між Влучністю (Precision) та Повнотою (Recall), усереднене по класах	Багатокласове оцінювання логічного виведення
t-критерій Стьюдента	$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{s_1^2 / n_1 + s_2^2 / n_2}}$	Перевірка статистичної значущості покращення метрик між двома моделями

4.2.1 Експериментальна установка: набори даних та базові моделі

Для оцінювання ЕМТКД було сформовано експериментальне середовище, яке моделює сценарій впровадження системи автоматизованого аналізу в умовах гетерогенності обладнання. Завданням експерименту було кількісне тестування гіпотези щодо здатності динамічного ансамблю моделей-вчителів у комбінації з алгоритмами напівкерованого навчання компенсувати вплив доменного зсуву при використанні обмеженого обсягу розмічених даних цільового домену.

Експериментальна база даних була сформована на основі трьох масштабних масивів цифрових рентгенограм грудної клітки. Усі зображення пройшли етап стандартизації попереднього опрацювання: перетворення у формат 16-бітних градацій сірого, зміна просторової роздільної здатності до розміру 224×224 пікселі

(вимога архітектури енкодерів сімейства ResNet) та застосування адаптивної нормалізації локального контрасту на основі гістограми (CLAFE).

Дані були класифіковані за функціональними ролями:

а) ChestX-ray14 (CXR14) – початковий домен 1: набір даних містить 112 120 фронтальних рентгенограм від 30 805 пацієнтів, що зібрані в Клінічному центрі НІН (США). Цей набір містить анотації для 14 класів патологій і використовувався для ітеративного навчання першої моделі-вчителя в ансамблі.

б) CheXpert – початковий домен 2: набір даних охоплює 224 316 зображень від 65 240 пацієнтів (дані Стенфордського медичного центру). Включає фронтальні та латеральні проєкції зі зміщеним розподілом патологічних знахідок порівняно з набором CXR14. Цей набір слугував навчальною вибіркою для другого вчителя для моделювання альтернативного розподілу візуальних ознак.

в) MIMIC-CXR – цільовий домен: набір даних складається з 377 110 зображень з медичного центру Beth Israel Deaconess. У межах експериментів цей набір даних використаний як цільове тестове середовище для перевірки адаптаційних властивостей запропонованого методу.

Для імітації умов обмеженого доступу до розмічених даних, процес тонкого налаштування моделі-учня здійснювався з використанням обмежених стратифікованих підвбірок із набору MIMIC-CXR обсягом 500, 1000 та 2000 анотованих зображень відповідно.

Для усунення впливу мультилейблового дисбалансу рідкісних хвороб клінічна задача класифікації була зведена до формалізованого сценарію бінарної класифікації: виявлення ознак будь-якої легеневої патології (макро-клас «Патологія») проти їхньої відсутності (макро-клас «Норма»). Таке спрощення дало можливість ізолювати ефект адаптації домену від похибок, притаманних мультикласовій класифікації. Процедура навчання супроводжувалася 5-кратною перехресною перевіркою (див. рис. 4.7) для зменшення значення дисперсії статистичних оцінок.

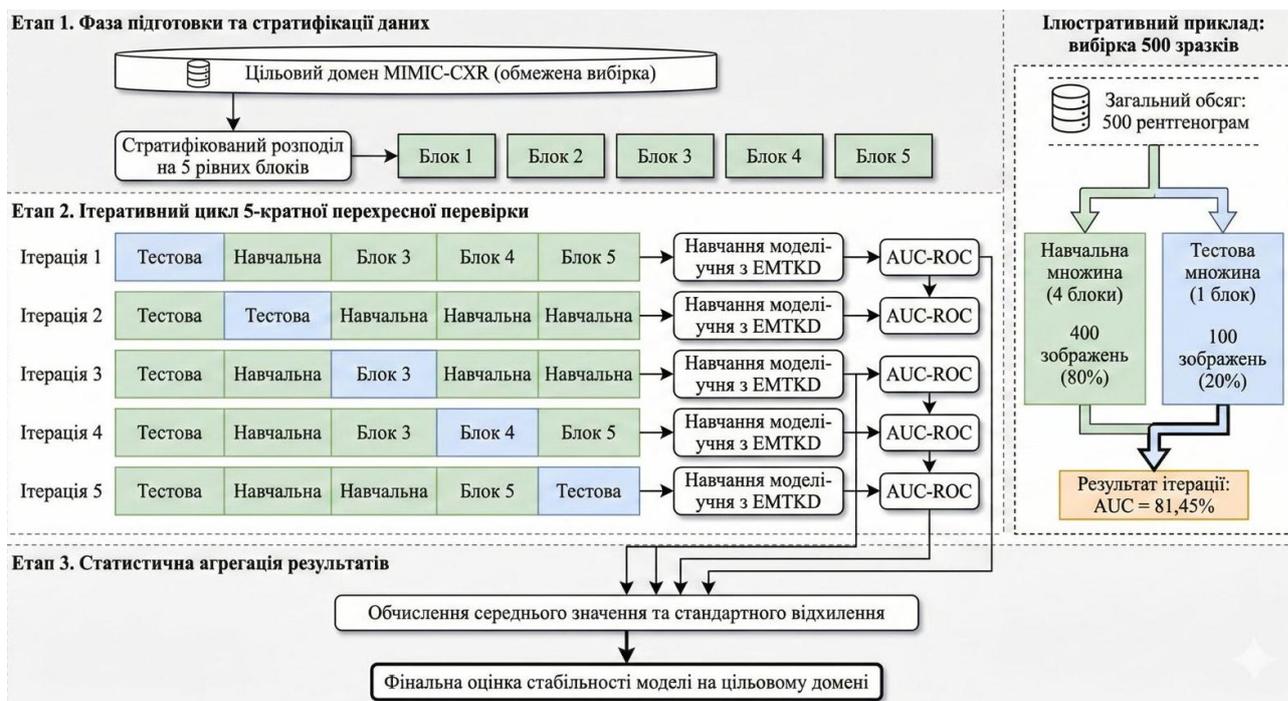


Рисунок 4.7 – Схема 5-кратної перехресної перевірки, що застосована до оцінювання стабільності EMTKD на цільовому домені за обмеженої розмітки

Для порівняльного аналізу навченої моделі-учня за удосконаленням EMTKD було реалізовано низку базових моделей:

1. Target Only (Supervised Baseline): архітектура ResNet-18, параметри якої оптимізувалися лише на обмеженій вибірці цільового домену (500–2000 зразків). Використовувалася для оцінювання ступеня перенавчання в умовах дефіциту даних.

2. Source Only (Direct Transfer): модель архітектури ResNet-50, попередньо навчена на повному обсязі даних CheXpert. Оцінювання відбувалося на масиві MIMIC-CXR без застосування процедур адаптації. Демонструє масштаб зниження точності через доменний зсув.

3. Fine-tuning (Transfer Learning): модель, попередньо навчена на об'єднаному масиві початкових доменів (CXR14 та CheXpert), що пройшла етап донавчання на малій вибірці цільового домену.

4. DANN: реалізація архітектури змагальної доменної адаптації із застосуванням шару інверсії градієнта для екстракції доменно-інваріантних ознак.

4.2.2 Аналіз результатів експериментального дослідження методу адаптивної дистиляції знань

Основною метрикою оцінювання якості класифікації є AUC-ROC, з огляду на її стійкість до дисбалансу класів, що властиве медичним вибіркам. Усі кількісні результати експериментів, які отримані на незалежній тестовій підвибірці MIMIC-CXR, зведено в табл. 4.3.

Таблиця 4.3

Порівняння результативності методів адаптації домену на тестовому наборі MIMIC-CXR; результати подано як середнє значення AUC-ROC (у %) \pm стандартне відхилення за 5 незалежними запусками; більші значення відповідають кращим показникам

Метод	500 зразків	1000 зразків	2000 зразків
Target Only (ResNet-18)	72,15 \pm 1,20	75,40 \pm 0,95	78,10 \pm 0,80
Source Only (ResNet-50)	74,80 \pm 0,00	74,80 \pm 0,00	74,80 \pm 0,00
Тонке налаштування	76,50 \pm 0,85	79,20 \pm 0,70	81,50 \pm 0,60
DANN	77,10 \pm 1,05	79,80 \pm 0,90	82,20 \pm 0,75
EMTKD (запроп.)	81,45 \pm 0,65	83,90 \pm 0,55	86,10 \pm 0,50

Аналіз даних із табл. 4.3 виявляє закономірності щодо роботи аналізованих методів. Базова модель Target Only показує найнижчі результати за мінімального розміру вибірки (500 зразків). Цей факт узгоджується із загальновідомою проблематикою навчання глибоких мереж «з нуля» за умови недостатньої кількості навчальних прикладів. Модель Source Only демонструє, що пряме застосування ваг, отриманих на наборі CheXpert, на цільовий домен MIMIC-CXR призводить до стагнації метрики AUC-ROC на рівні 74,80 %, що зумовлено чутливістю згорткових фільтрів до змін у розподілі інтенсивностей пікселів та артефактів іншого сканера.

Модель, що створена за удосконаленням EMTKD, демонструє статистично значуще (рівень значущості $p < 0,01$ за t-критерієм Стьюдента) покращення

метрики порівняно з усіма базовими підходами. На вибірці з 500 зразків модель-учень досягає показника AUC-ROC 81,45 %, що перевищує результати методів DANN (на 4,35 %) та Fine-tuning (на 4,95 %). Дані показники емпірично доводять висунуту гіпотезу щодо ефективності передачі так званих «м'яких» міток від моделей-вчителів. Учень оптимізує свої ваги не лише на основі дискретних бінарних міток (хворий/здоровий), а й із врахуванням неперервних розподілів ймовірностей, згенеровані ансамблем, засвоюючи приховані співвідношення між патологіями.

Для оцінювання впливу окремих компонентів ЕМТКД на загальну результативність створеної моделі-учня було проведено абляційне дослідження (англ. «ablation study»). Кількісні результати класифікації наведено в табл. 4.4.

Таблиця 4.4

Абляційне дослідження: вплив адаптивного зважування (AW), доменної адаптації (DA) та напівкерovanого навчання (SSL) на результативність цільового домену; усі значення подані у %; більші значення відповідають кращим показникам

Варіант моделі	Accuracy	Precision	Recall	F ₁ -macro	AUC-ROC
ЕМТКД без AW	84,0	83,0	83,5	83,2	88,5
ЕМТКД без DA	81,2	80,0	80,5	80,2	85,0
ЕМТКД без SSL	85,5	84,5	85,0	84,7	89,5
ЕМТКД	88,5	87,5	88,0	87,7	92,5

Зазначимо, що останній рядок у табл. 4.4 містить значення метрик повної конфігурації моделі-учня за ЕМТКД, у якій активовано всі три досліджувані механізми: адаптивне зважування (AW), доменна адаптація (DA) та напівкерované навчання (англ. «Self-Supervised Learning», SSL). Ці значення слугують спільним еталоном для обчислення втрат точності внаслідок вимкнення компонента.

Візуалізація багатовимірного латентного простору ознак цільового домену здійснювалася із застосуванням алгоритму стохастичного вкладення сусідів із t-розподілом (t-SNE). Вхідними даними для t-SNE слугували багатовимірні вектори активацій передостаннього шару згорткової мережі (рис. 4.8).

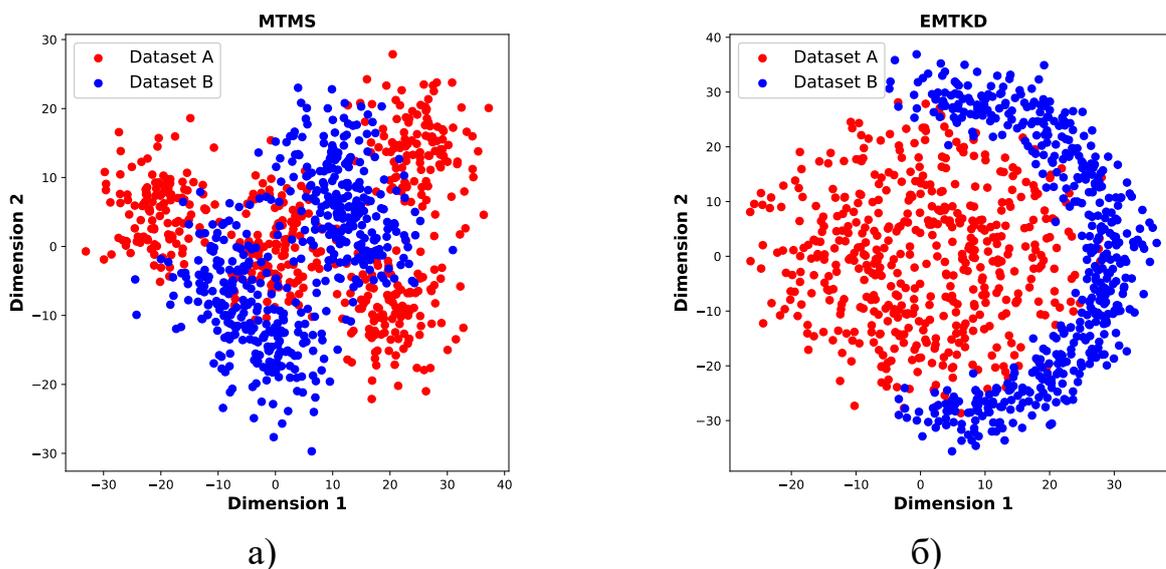


Рисунок 4.8 – Візуалізація багатовимірному простору ознак за допомогою алгоритму t-SNE: а) базовий метод демонструє значне хаотичне перекриття класів із різних доменів; б) модель-учень за EMTKD формує чіткі, щільні та відокремлені кластери

Аналіз двовимірних проєкцій показує, що модель-учень за EMTKD забезпечує вищий рівень лінійної роздільності об'єктів різних класів у просторі ознак цільового домену. На рис. 4.9 зображено візуалізацію динамічного розподілу вагових коефіцієнтів w_i , що генеруються механізмом адаптивного зважування вчителів.

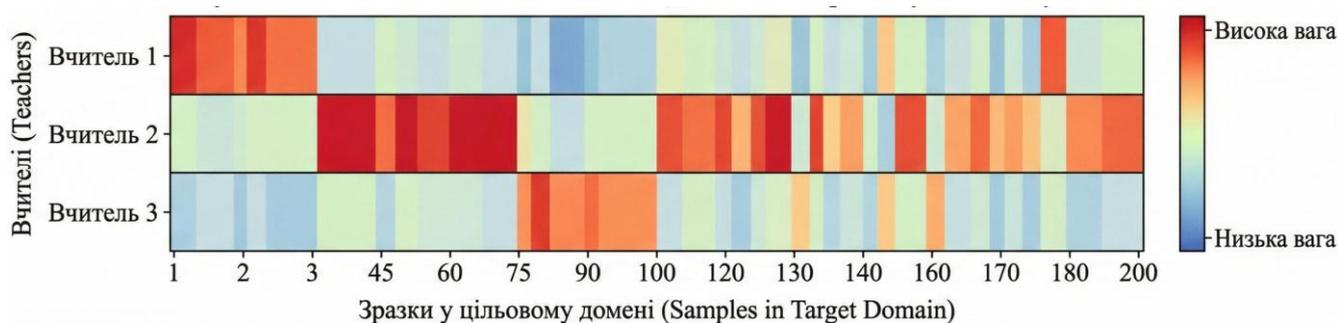


Рисунок 4.9 – Візуалізація адаптивних ваг $w_i(x)$ для трьох вчителів на вибірці з 200 зразків цільового домену

На рис. 4.9 яскравіші (тепліші) кольори відповідають вищій призначеній вазі, що демонструє здатність архітектури динамічно обирати найбільш компетентного

експерта для кожного зображення. Даний механізм на етапі інференсу призначає більшу вагу тому вчителю з ансамблю, дисперсія передбачень якого є найменшою (тобто впевненість якого є найвищою) для конкретного вхідного зображення. Такий підхід знижує ймовірність передачі хибних знань.

Оцінювання збалансованості класифікаційної моделі здійснювалося за допомогою побудови матриці помилок, що наведена на рис. 4.10.

Actual	Normal	480	20
	Pathological	15	485
		Normal	Pathological
		Predicted	

Рисунок 4.10 – Матриця помилок для створеної моделі-учня за ЕМТКД на цільовому домені; висока діагональна концентрація свідчить про збалансовані Precision та Recall

Графік динаміки зміни функції втрат на тестовій вибірці впродовж епох навчання подано на рис. 4.11.

Спостережувана швидша збіжність цільової функції в моделі-учня за ЕМТКД математично пояснюється тим, що використання неперервних розподілів ймовірностей від навченого ансамблю відіграє роль потужного природного регуляризатора. Він згладжує багатовимірний ландшафт функції втрат і запобігає конвергенції параметрів моделі в локальні мінімуми, що є типовою проблемою при оптимізації на жорстких бінарних векторах.

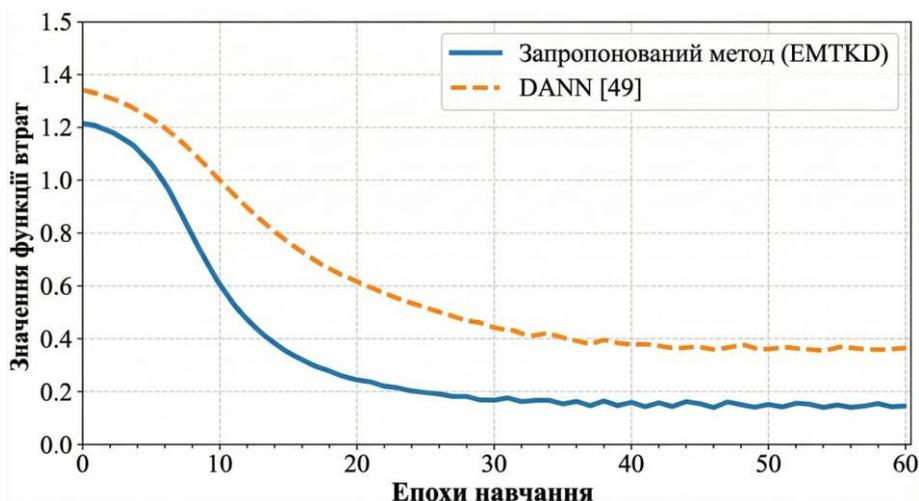


Рисунок 4.11 – Динаміка зменшення функції втрат під час навчання: запропонований метод (суцільна лінія) демонструє швидшу збіжність та нижче фінальне значення втрат порівняно з DANN (пунктирна лінія)

Діаграма кумулятивного внеску на рис. 4.12 узагальнює результати абляційного аналізу та вказує на те, що видалення будь-якого компонента із запропонованої тріади, а саме, модулів напівкерованого навчання, адаптивного зважування або доменної адаптації, супроводжується статистично значущим зниженням інтегральної точності класифікації.

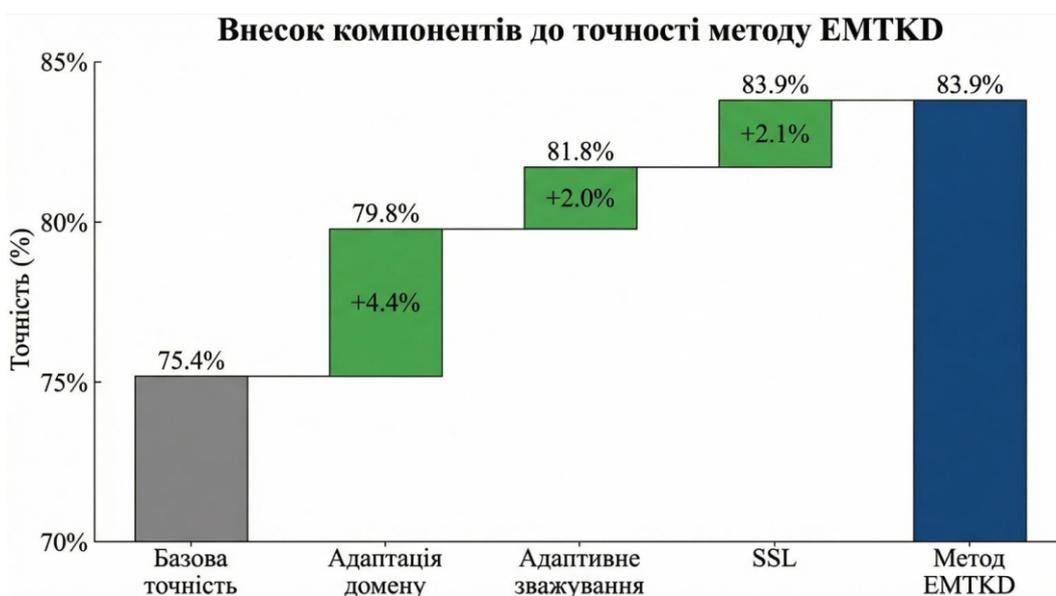


Рисунок 4.12 – Діаграма результатів абляційного дослідження: кумулятивний внесок кожного структурного компонента (доменна адаптація, напівкероване навчання SSL, адаптивне зважування) у загальну підсумкову точність моделі

4.3. Експериментальне дослідження методу встановлення смислових зв'язків у медичних текстах

Наступний етап експериментальних досліджень передбачав емпіричну валідацію розробленої гібридної нейромережевої моделі за удосконаленим методом OPNI.

4.3.1 Експериментальна установка та набори даних

Емпіричне оцінювання удосконаленого методу OPNI здійснювалося на основі масиву даних MedNLI, який визнаний науковою спільнотою як еталонний бенчмарк для задач NLP у клінічному домені. Цей масив сформований експертами-клініцистами на основі деідентифікованих записів із відкритої бази даних реанімаційних відділень MIMIC-III (що включає виписні епікризи, нотатки персоналу, радіологічні звіти).

Структура елементів у наборі MedNLI запропонована парами текстових фрагментів: «Засновок» (англ. «premise») та «Гіпотеза» (англ. «hypothesis»). Алгоритмічне завдання полягає у визначенні класу логічного відношення між цими твердженнями. Доступні три класи:

1) «Логічне слідування» (англ. «entailment»): абсолютне логічне слідування між двома медичними твердженнями ;

2) «Суперечність» (англ. «contradiction»): пряма медична або логічна суперечність між двома твердженнями;

3) «Невизначеність» (англ. «neutral»): бракує інформації для підтвердження або спростування.

Для забезпечення достовірності результатів та унеможливлення витоків даних набір було стратифіковано на три незалежні підмножини зі збереженням рівномірного розподілу класів по 33,3 % для кожного класу (див. рис. 4.13):

– навчальна вибірка: 11 232 пари речень, що використані для ітеративної оптимізації вагових коефіцієнтів за допомогою градієнтного спуску;

– валідаційна вибірка: 1 395 пар, що використані ізольовано для моніторингу функції втрат та налаштування гіперпараметрів; до цієї вибірки застосовано механізм ранньої зупинки навчання для уникнення перенавчання.

– тестова вибірка: 1 422 пари, що зарезервовані для підсумкового, одноразового обчислення метрик якості.

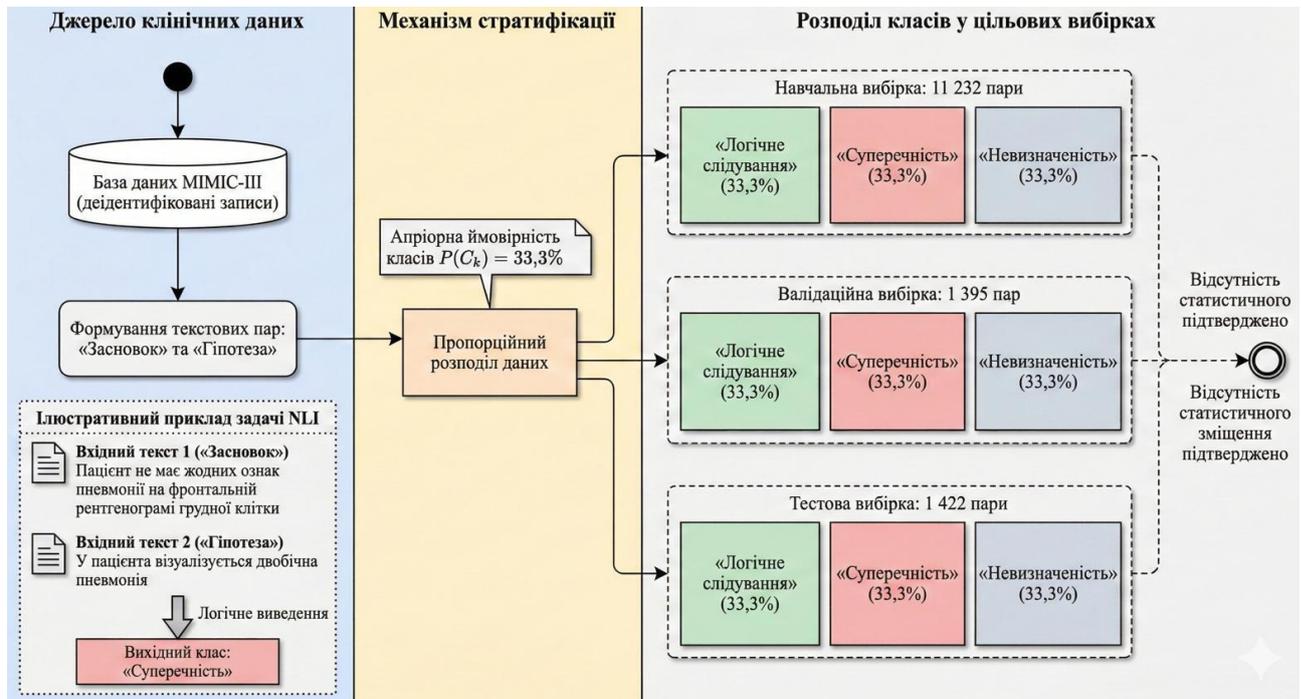


Рисунок 4.13 – Діаграма розподілу класів у наборі даних MedNLI, що підтверджує відмінне балансування навчальної вибірки та відсутність статистичного зміщення апріорних ймовірностей

Програмна модель була реалізована в середовищі PyTorch. У ролі базового кодувальника синтаксису застосовано рекурентну нейронну мережу BioELMo, що формує потужні контекстуалізовані вектори слів фіксованою розмірністю 1024. Вектори вбудовувань для медичних концептів з онтології UMLS (розмірністю 100) динамічно генерувалися за допомогою трансляційної графової моделі MultE. Остання була попередньо навчена на підграфі UMLS, що містив виключно терміни, наявні в лексиконі масиву MedNLI.

Процедура навчання формалізована такими технічними параметрами:

– оптимізатор: використано алгоритм Adam зі стандартними імпульсними параметрами $\beta_1 = 0,9$ та $\beta_2 = 0,999$;

– швидкість навчання: встановлено початкове значення 1×10^{-4} , з подальшим динамічним експоненційним зменшенням за допомогою планувальника ReduceLROnPlateau у випадку виходу функції втрат на плато;

– цільова функція: категоріальна перехресна ентропія;

– регуляризація: використано метод Dropout із коефіцієнтом ймовірності 0,5 для регуляризації повнозв'язних шарів фінального класифікатора;

– розмір пакету: 32 пари речень для забезпечення стабільності градієнта.

Для проведення порівняльного аналізу було реалізовано три базові архітектури:

1) ESIM-know: структурна модель, що використовує вектори знань UMLS, проте не має модулів аналізу локальної тональності чи заперечень;

2) BioELMo (Baseline): базова рекурентна модель без підключення зовнішніх баз онтологічних знань;

3) BioELMo+Sentiment: модифікована модель, доповнена вектором аналізатора тональності, але позбавлена доступу до графа UMLS.

4.3.2 Результати та аналіз помилок

Для забезпечення повної статистичної достовірності кожен експеримент повторювався 5 разів із різними значеннями параметрів випадкової ініціалізації. Середні значення метрик та їхні стандартні відхилення на ізольованому наборі наведено в табл. 4.5.

Детальний аналіз результатів тестування показує, що гібридна модель досягає значення загальної точності 81,14 %, що статистично значущо перевершує показники базової моделі BioELMo (приріст становить 1,41 %). Щодо задач медичного NLI, де покращення метрик ускладнюється термінологічною варіативністю, то даний приріст може розглядатися як суттєвий показник розуміння тексту.

Таблиця 4.5

Порівняльна характеристика результативності моделей на тестовому наборі MedNLI; усі значення наведено в %

Модель	Accuracy ↑	Precision ↑	Recall ↑	F ₁ -macro ↑
BioELMo (Baseline)	79,73 ± 0,45	78,55 ± 0,50	78,15 ± 0,48	78,23 ± 0,46
ESIM-know (UMLS)	80,22 ± 0,40	79,05 ± 0,42	78,67 ± 0,45	78,76 ± 0,41
BioELMo + Sentiment	80,60 ± 0,38	79,48 ± 0,35	79,30 ± 0,39	79,19 ± 0,37
Гібридна модель (запроп.)	81,14 ± 0,31	80,08 ± 0,35	79,62 ± 0,40	79,85 ± 0,33

Для актуалізації порівняння, оскільки базова модель BioELMo була розроблена раніше, розроблений гібридний метод був також зіставлений із сучасними ВММ, такими як спеціалізована ClinicalT5 та відкрита LLaMA-3-8B-Instruct. Результати обчислювальних експериментів подано в табл. 4.6 та проілюстровано на рис. 4.14.

Таблиця 4.6

Порівняння моделі за удосконаленим методом OPNI із сучасними ВММ на наборі даних MedNLI

Модель	Ассурагу (%)	Кількість параметрів	Вимоги до VRAM	Час інференсу, мс/пара
ClinicalT5-Base	82,40	220 млн.	~4 ГБ	~15 мс
LLaMA-3-8B	78,50	8 мільярдів	~16 ГБ	~120 мс
Med-PaLM-2	86,10	> 300 млрд.	Хмарний API	N/A (затримка мережі)
Гібридна (запроп.)	81,14	~110 млн.	< 2 ГБ	~5 мс

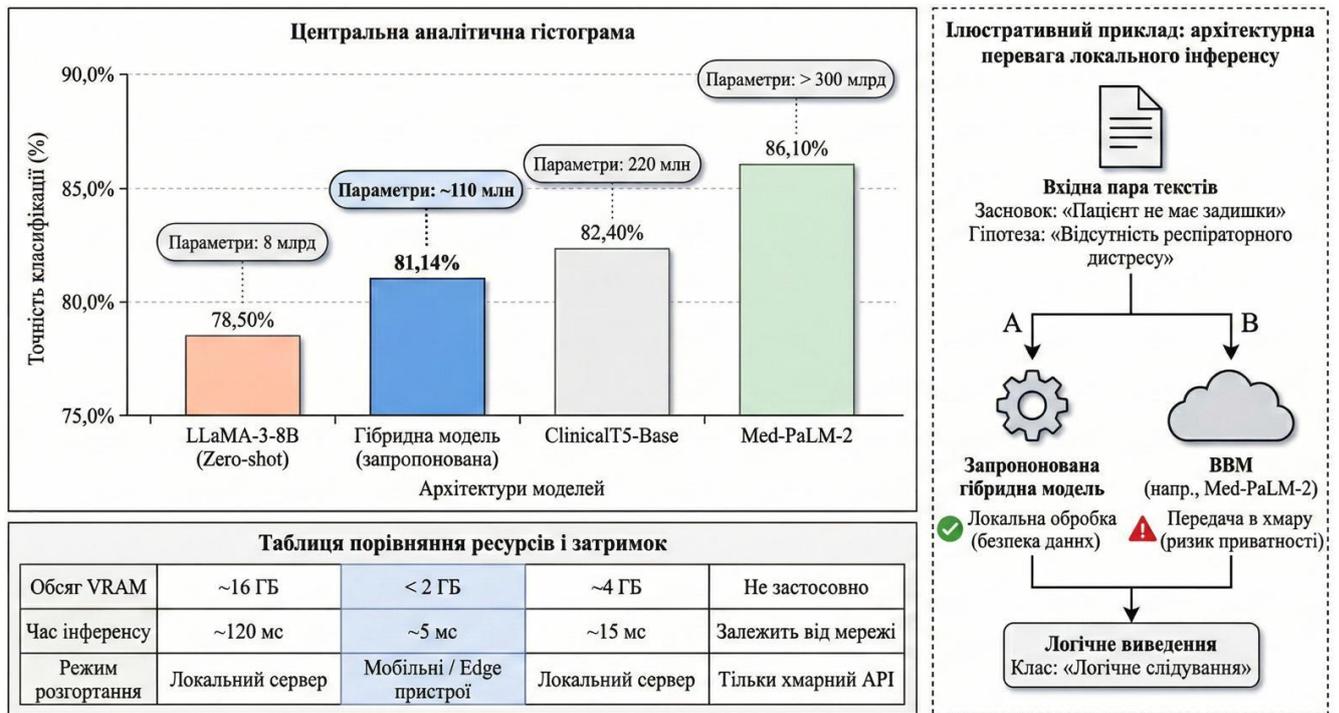


Рисунок 4.14 – Гістограма порівняння точності створеної моделі за удосконаленим методом OPNI із сучасними LLM; попри менший обсяг параметрів, запропонований метод демонструє високу точність (Accuracy), значно перевершуючи LLaMA-3 у режимі zero-shot

Аналіз табл. 4.6 та рис. 4.14 вказує на те, що хоча великі пропріетарні LLM, як от Med-PaLM-2 демонструють вищу точність (Accuracy) близько 86 %, їхнє розгортання в медичних закладах пов'язане із обмеженнями інференсу за реальних умов: високими вимогами до обчислювальних ресурсів, загрозою генерації галюцинацій та необхідністю обробки конфіденційних даних у хмарних сервісах (що суперечить стандартам HIPAA). Натомість запропонована гібридна модель вимагає менше ніж 2 ГБ відеопам'яті та забезпечує швидкість інференсу приблизно 5 мілісекунд, що дає змогу її безпечно локальне виконання.

Для аналізу специфічності класифікатора побудовано ROC-криві (рис. 4.15) та агреговану матрицю помилок (рис. 4.16).

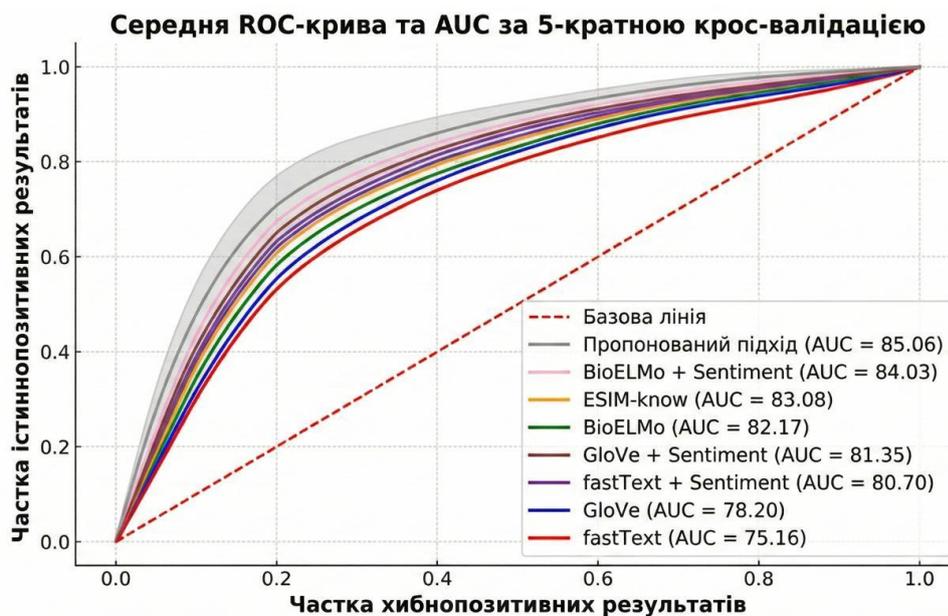


Рисунок 4.15 – ROC-криві для запропонованої моделі NLI на еталонному наборі даних MedNLI



Рисунок 4.16 – Матриця помилок для NLI моделі: нормалізація виконана по горизонтальних рядках; візуалізується високе значення Recall розпізнавання класів «Логічне слідування» (89 %) та «Суперечність» (96 %)

Особливістю подання матриці помилок на рис. 4.16 є те, що нормалізація відсотків виконана горизонтальними рядками (сума в кожному рядку дорівнює 100 %). Це дає змогу об'єктивно оцінити частку правильних та хибних передбачень (чутливість моделі) для кожної логічної категорії незалежно від можливого

дисбалансу вибірки. Кількість зразків у матриці складає 3 200 одиниць для кожного класу, що перевищує обсяг тестової вибірки (1 422 пари), оскільки рис. 4.16 демонструє сумарний результат 5-кратної перехресної перевірки, що застосований до об'єднаного масиву даних. Такий підхід забезпечує стабільнішу оцінку.

Розподіл кількості зразків за 5-кратної перехресної перевірки подано у табл. 4.7.

Таблиця 4.7

Розподіл кількості зразків за 5-кратної перехресної перевірки (5 блоків)

Номер блоку	Клас «Логічне слідування»	Клас «Суперечність»	Клас «Невизначеність»
Блок 1	640	640	640
Блок 2	640	640	640
Блок 3	640	640	640
Блок 4	640	640	640
Блок 5	640	640	640
Загалом	3 200	3 200	3 200

На рис. 4.16 спостерігається вагоме підвищення повноти (Recall) для найскладнішого класу «Суперечність» з 82 % до 96 %. Цей результат є наслідком інтеграції інструмента NegEx, який формалізує процес виявлення лексичних заперечень, що дає змогу мережі математично розрізняти стверджувальні та заперечні форми.

Водночас аналіз окремих випадків (див. рис. 4.17) показує, що доступ до онтології UMLS дає змогу системі визначати приховані семантичні зв'язки (наприклад, належність препарату «Лазикс» до загального класу «Діуретики»), які складно ідентифікувати за допомогою лише контекстуальних вбудовувань базової моделі BioELMo. На рис. 4.17 бачимо, що модуль системи знаходить прихований семантичний шлях між термінами «Лазикс» та «Діуретик», забезпечуючи правильне логічне виведення (клас «Логічне слідування»).

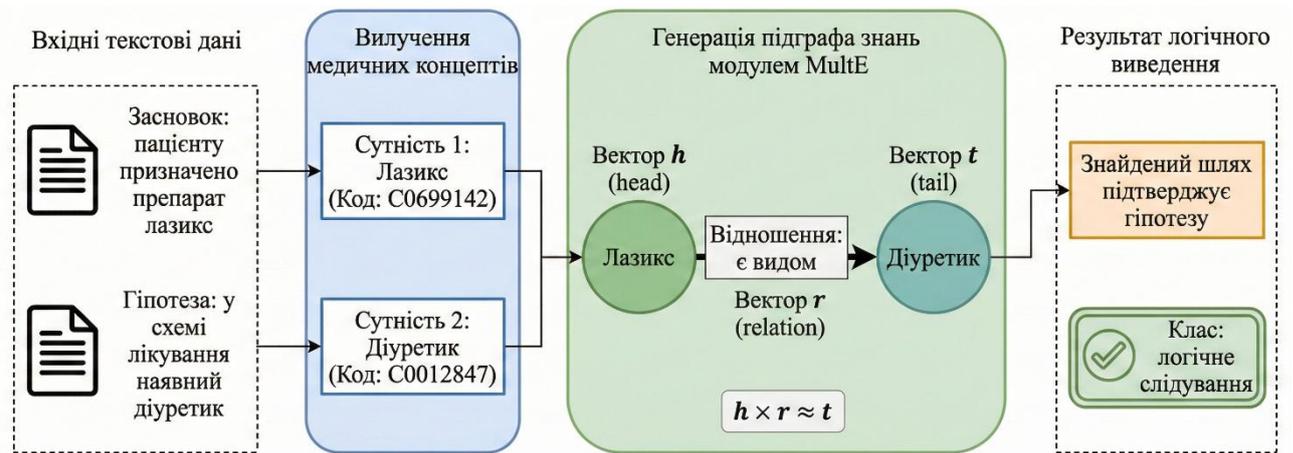


Рисунок 4.17 – Візуалізація підграфа медичних знань, який згенерований модулем MultE; модель системи знаходить прихований семантичний шлях між термінами «Лазикс» та «Діуретик», забезпечуючи правильне логічне виведення (клас «Логічне слідування»)

Водночас метод має об'єктивні обмеження. Його ефективність залишається залежною від попередньої якості роботи інструменту MetaMap під час вилучення концептів, а також від повноти бази знань UMLS. Помилки лексичного попереднього оброблення можуть знижувати загальну якість класифікації. Проте, отримані результати свідчать про те, що запропонований гібридний підхід підвищує логічну узгодженість аналізу клінічних записів.

4.4. Експериментальна дослідження методів сегментації та ідентифікації патологій за зображенням МРТ серця

Завершальний етап досліджень передбачав експериментальне тестування методу SKIF-Seg для аналізу та сегментації зображень МРТ серця, а також методу KI-GCN для оцінювання якості ідентифікації патологій серця за зображенням МРТ серця. Головне завдання на цьому етапі полягало в оцінюванні здатності алгоритму гарантувати анатомічно коректні топологічні відношення між структурами серця, як от вкладеність порожнини ЛШ всередину Міо, суміжність шлуночків, які часто порушуються стандартними нейронними мережами, що оптимізуються виключно на попіксельну точність.

4.4.1 Опис експериментального середовища та методології

Методи SKIF-Seg та KI-GCN функціонують у межах єдиного нерозривного обчислення даних системи «IDK Medical AI». На рис. 4.18 зображено процес перетворення піксельних масок сегментації у вузли графа пацієнта для подальшого обчислення фінальних ймовірностей патологій.

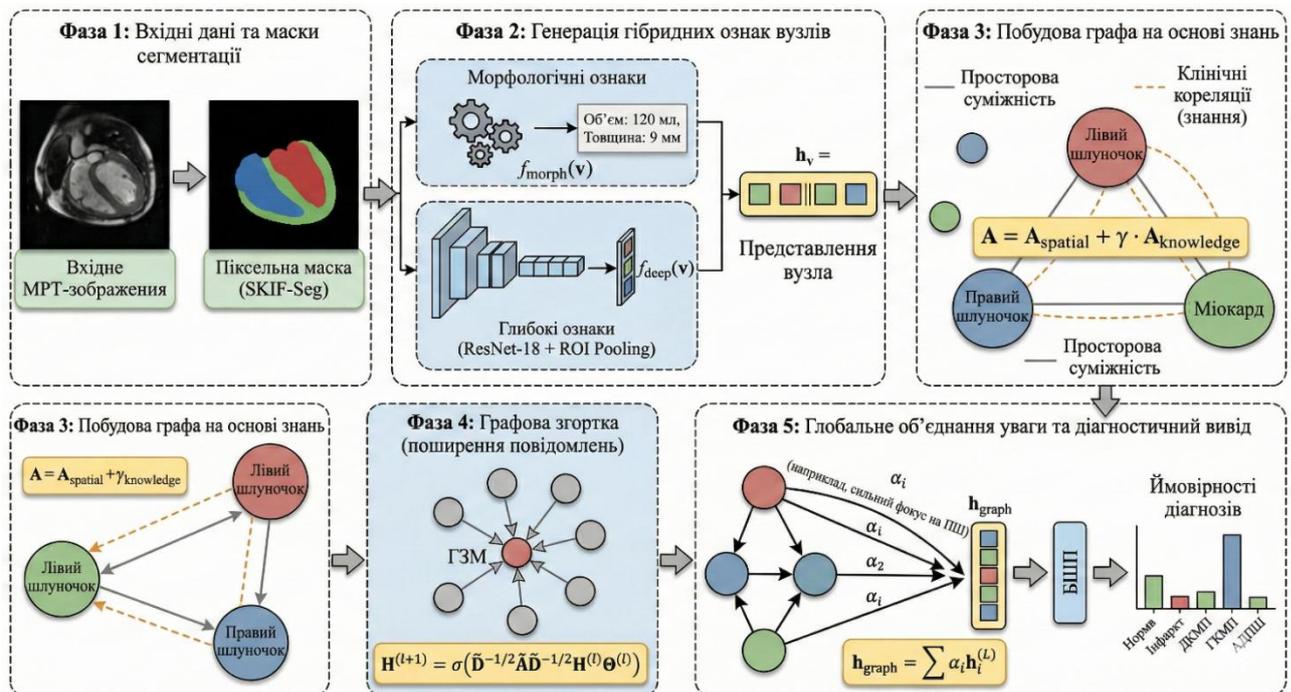


Рисунок 4.18 – Блок-схема графового логічного виведення модуля KI-GCN у розробленій системі, що відображає динамічний процес перетворення піксельних масок у вузли графа пацієнта та обчислення фінальних ймовірностей діагнозів

Тестування базувалося на двох міжнародних наборах даних: ACDC та M&Ms-2. Набір ACDC містить повноцінні 4D МРТ-зображення від 100 пацієнтів, які пропорційно розділені на 5 клінічних груп (по 20 осіб у кожній):

- NOR: здорова контрольна група;
- MINF: пацієнти з перенесеним інфарктом Міо (локальні порушення скоротливості);
- DCM: дилатаційна кардіоміопатія (збільшення об'єму ЛШ);
- HCM: гіпертрофічна кардіоміопатія (значне потовщення стінок Міо);

– ARV: аритмогенна дисплазія ПШ.

Просторова обробка вхідних даних у форматі NIfTI включала сплайн-ресемплінг до єдиної ізотропної роздільної здатності (1.37 мм/піксель), Z-score нормалізацію інтенсивностей вокселів та генерацію двовимірних зрізів по короткій осі серця. Валідація здійснювалася за стратегією 4-кратної перехресної перевірки з групуванням на рівні пацієнтів, що математично унеможлиблює змішування зрізів одного пацієнта в навчальній та тестовій вибірках.

Досліджувалися такі конфігурації моделей для ізолюваного оцінювання:

1) U-Net (Baseline): базова архітектура з класичною композитною функцією втрат $\mathcal{L}_{CE} + \mathcal{L}_{Dice}$;

б) U-Net + EGA: базова модель, що доповнена механізмом EGA для фокусування на розмитих межах;

в) U-Net + ТААС: базова архітектура із використанням штрафної топологічної функції втрат на основі карт SDF;

г) SKIF-Seg: нейромережева модель за розробленим методом, що поєднує синергетичні компоненти EGA та ТААС.

Матричні обчислення виконувалися на графічному прискорювачі NVIDIA GPU RTX 3080. Генерація масивів SDF відбувалася динамічно на етапі навчання з використанням оптимізованих алгоритмів розрахунку точної евклідової відстані.

4.4.2 Результати та аналіз анатомічної коректності

Для комплексного оцінювання точності застосовувалися метрики EDT для глобального оцінювання площі перекриття та HD95 для прецизійного оцінювання просторової точності меж. Значення метрик на тестовій вибірці ACDC наведено в табл. 4.8.

Аналіз результатів у табл. 4.8 демонструє, що інтеграція ТААС у поєднанні з механізмом EGA дає змогу досягти суттєвого зниження метрики HD95, особливо для Mio (з 9,8 мм до 6,5 мм), що свідчить про усунення топологічних викидів та підвищення надійності вхідних даних для наступного етапу класифікації.

Таблиця 4.8

Результати сегментації основних структур серця на тестовій вибірці набору ACDC за метриками DSC (%) та HD95 (мм)

Модель	ЛШ		ПШ		Міо	
	DSC ↑	HD95 ↓	DSC ↑	HD95 ↑	DSC ↑	HD95 ↑
U-Net (Baseline)	93,0 ± 1,6	8,0 ± 2,2	90,0 ± 2,1	8,5 ± 2,5	85,5 ± 2,5	9,8 ± 3,1
U-Net + EGA	93,8 ± 1,5	7,2 ± 2,0	91,0 ± 2,0	7,8 ± 2,3	86,5 ± 2,4	8,9 ± 2,9
U-Net + ТААС	94,5 ± 1,4	6,5 ± 1,9	92,0 ± 1,8	7,0 ± 2,1	87,8 ± 2,2	7,5 ± 2,5
SKIF-Seg (запроп.)	95,5 ± 1,2	5,5 ± 1,8	93,0 ± 1,7	6,0 ± 2,0	89,0 ± 2,0	6,5 ± 2,3

Порівняння запропонованого методу з наявними сучасними алгоритмічними архітектурами-аналогами наведено в табл. 4.9.

Таблиця 4.9

Порівняння результатів класифікації з сучасними методами на тестовій вибірці набору даних ACD за показником DSC

Метод	ЛШ ↑	Міо ↑	ПШ ↑	Avg DSC ↑
U-Net [13]	0,951	0,895	0,930	0,925
nnU-Net [89]	0,968	0,909	0,945	0,941
MedNeXt [83]	0,966	0,910	0,942	0,939
SKIF-Seg	0,965	0,912	0,941	0,939

Аналіз даних табл. 4.9 вказує на те, що модель за методом SKIF-Seg демонструє результати, що є співставними сучасним рішенням (nnU-Net), а у випадку найскладнішої для розпізнавання структури, Міо, досягає значення DSC 0,912. Зменшення метрики HD95 (з 9,8 мм до 6,5 мм для Міо) свідчить про усунення ізольованих хибних ділянок сегментації («острівців») завдяки дії функції ТААС, що штрафує появу масок у зонах із високими значеннями SDF.

Коробчаста діаграма на рис. 4.19 відображає розподіл DSC та наочно підтверджує стабільність методу.

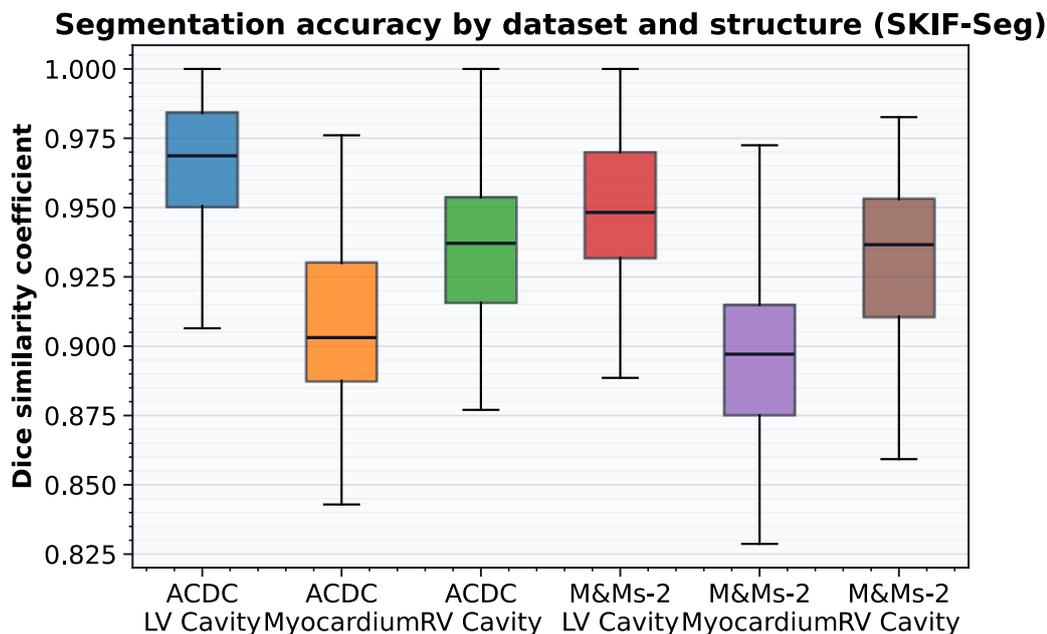


Рисунок 4.19 – Розподіл DSC для методу SKIF-Seg, протестованого на складних наборах ACDC та M&Ms-2; високі медіанні значення та малий міжквартильний розмах свідчать про стабільність роботи методу незалежно від клінічної картини

Результати абляційного аналізу (табл. 4.10) вказують на синергетичну взаємодію модулів EGA та ТААС. Модуль EGA допомагає мережі локально сфокусуватися на межах об'єктів, полегшуючи роботу штрафної функції ТААС, яка відповідає за глобальну форму.

Таблиця 4.10

Абляційне дослідження на наборі даних ACDC: кількісна оцінка абсолютного приросту продуктивності від впровадження втрати ТААС та модуля EGA під час їхнього покрокового додавання до базової архітектури U-Net; пп – процентні

пункти, мм – міліметри

Структура	+ ТААС (Δ DSC / Δ HD95)	+ EGA (Δ DSC / Δ HD95)
ЛШ	1,0 пп / 1,3 мм	0,4 пп / 0,5 мм
Міо	2,1 пп / 2,5 мм	0,7 пп / 0,8 мм
ПШ	2,0 пп / 1,6 мм	0,8 пп / 0,9 мм

Візуальне порівняння сегментованих масок (рис. 4.20) ілюструє відновлення топологічної цілісності кільця Міо в складних клінічних випадках, де базова модель U-Net формує топологічний дефект у вигляді розриву. Також усунуто проблему перекриття порожнин шлуночків.

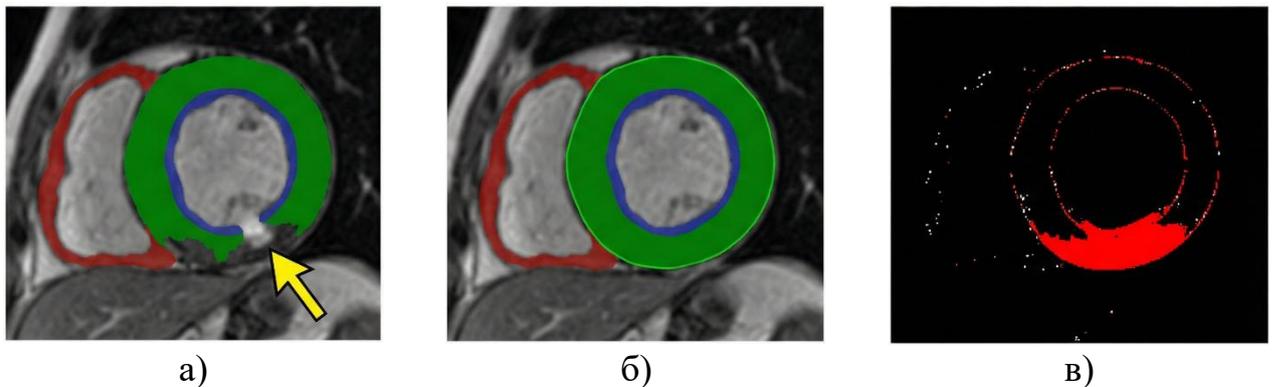


Рисунок 4.20 – Візуальне порівняння сегментації: а) базова U-Net з розривом Міо, б) SKIF-Seg з відновленою топологією та в) карта помилок, що демонструє зменшення хибних спрацьовувань на межах

Для кількісного оцінювання топологічної правдоподібності розраховано метрики: частота топологічних помилок (англ. «Topological Error Rate», TER), RingBreak (відсоток розривів Міо) та ClosedRing (відсоток суцільних масок). Дані подані в табл. 4.11 та на гістограмі (див. рис. 4.21).

Таблиця 4.11

Метрики топологічної правдоподібності: значне зменшення анатомічних помилок для SKIF-Seg порівняно з базовою U-Net; усі значення наведено в %

Набір даних	Модель	TER ↓	RingBreak ↓	ЛШ-ПШ-перетин ↓	ClosedRing ↑
ACDC	U-Net	9,1	10,5	2,6	89,4
	SKIF-Seg	3,4	4,1	0,6	96,8
M&Ms-2	U-Net	12,7	14,9	3,7	86,2
	SKIF-Seg	5,1	6,0	0,9	95,1

Topology metrics on ACDC (lower better, except ClosedRing%)

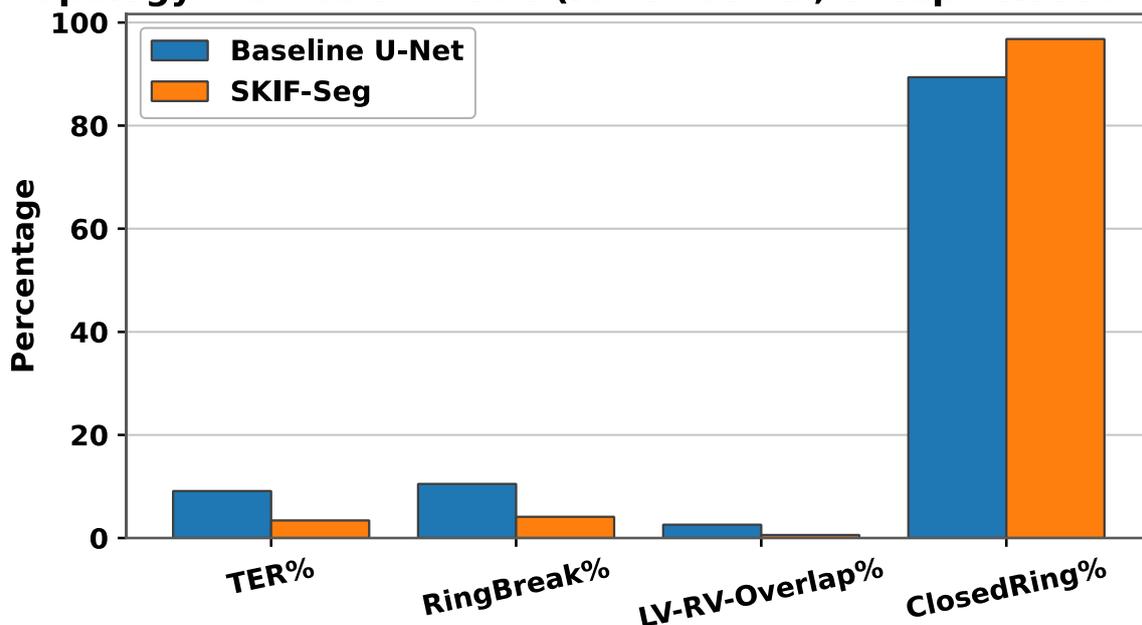


Рисунок 4.21 – Кількісна оцінка топологічної коректності: порівняння відношення (у %) топологічно валідних масок (Closed Rings) та частоти помилок (Ring Breaks)

Аналіз стійкості моделі до раптової зміни домену даних (тестування на наборі M&Ms-2) підтверджує збереження показників якості, що доводить узагальнюючу здатність моделі (табл. 4.12).

Таблиця 4.12

Деградація продуктивності SKIF-Seg при зміні домену; навчання – на ACDC, оцінювання – на тестовому M&Ms-2; ; пп – процентні пункти, мм – міліметри

Структура серця	Δ DSC (пп) ↓	Δ H95 (мм) ↓
ЛШ	1,5	1,3
Міо	1,8	1,4
ПШ	1,6	1,8

Топологічно коректні маски забезпечують надійне формування ознак для ідентифікації патологій серця за методом KI-GCN. Нормалізована матриця помилок на рис. 4.22 демонструє точність класифікації патологічних станів на рівні понад 95 % для складних класів кардіоміопатії.

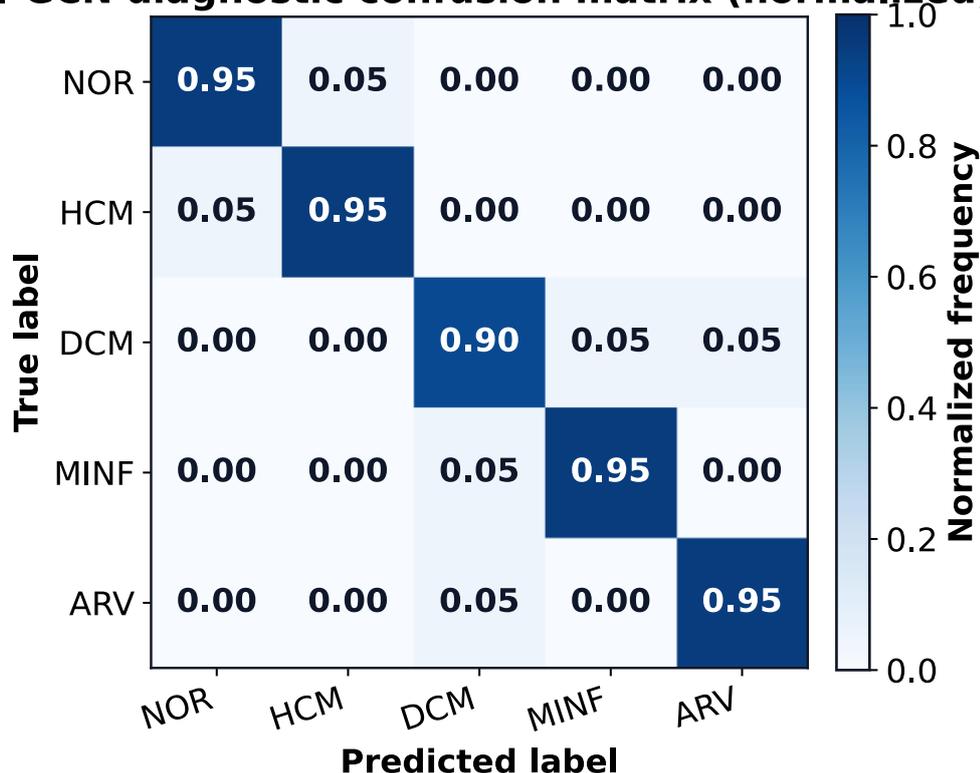
KI-GCN diagnostic confusion matrix (normalized)

Рисунок 4.22 – Матриця помилок за результатами класифікації методом KI-GCN; висока точність класифікації (особливо для класів HCM та DCM) підтверджує якість вхідних сегментаційних масок

Оцінювання математичного калібрування вихідних ймовірностей моделі за методом KI-GCN подано в табл. 4.13 та на діаграмі надійності (див. рис. 4.23).

Таблиця 4.13

Метрики калібрування до та після температурного масштабування; менші значення (↓) вказують на краще калібрування

Налаштування	Brier ↓	ECE ↓
Pre (без масштабування)	0,08	0,04
Post (temp. scaling, $\tau = 2,1$)	0,07	0,03

Застосування методу температурного масштабування дає змогу знизити показник ECE до 0,03, що свідчить про достовірність передбачень мережі.

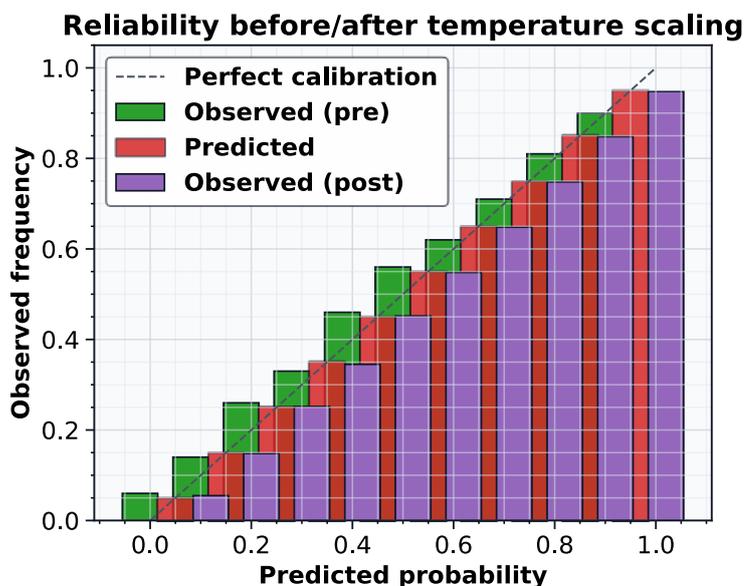


Рисунок 4.23 – Діаграма надійності для моделі класифікації за KI-GCN; близькість побудованої кривої (фіолетові стовпчики) до головної пунктирної діагоналі демонструє задовільне калібрування вихідних ймовірностей

Оцінювання обчислювальної складності інференсу (час обробки одного 3D-об'єму) показало, що нейромережева модель за методом SKIF-Seg демонструє збільшення обчислювальних витрат (+5 %) порівняно з базовою архітектурою U-Net при виконанні на GPU (рис. 4.24).

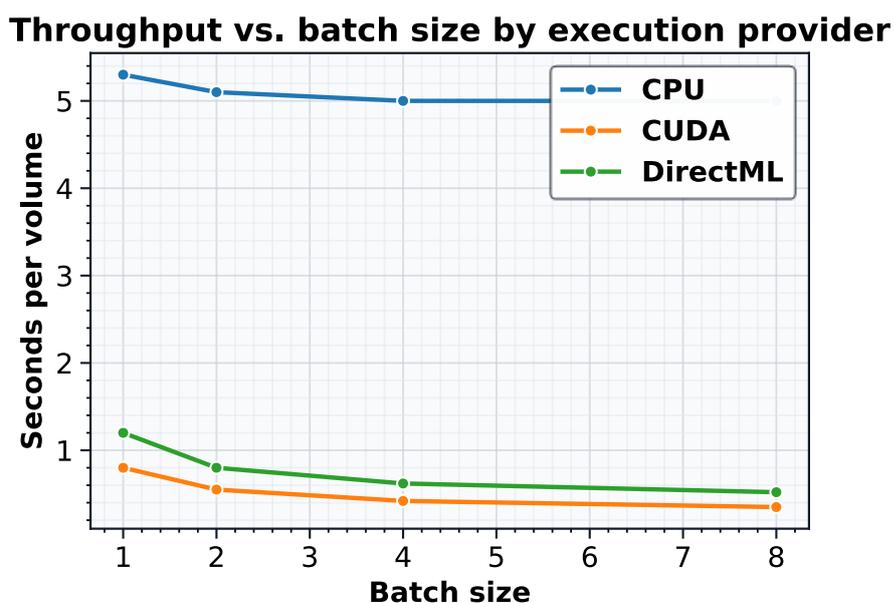


Рисунок 4.24 – Графік порівняння швидкості часу інференсу (1 мс / 1 МРТ-знімок) для різних апаратних конфігурацій обчислювачів (CPU, CUDA, DirectML)

Застосування методів математичного квантування вагових коефіцієнтів (перехід до формату FP16) дало можливість зменшити обсяг необхідної оперативної відеопам'яті вдвічі у випадку втрати загальної точності на рівні менше, ніж 0,1 % метрики DSC. На рис. 4.25 наведено діаграму Бланда-Альтмана, яка підтверджує клінічну узгодженість розрахованих моделлю об'ємів ЛШ з експертними оцінками лікарів.

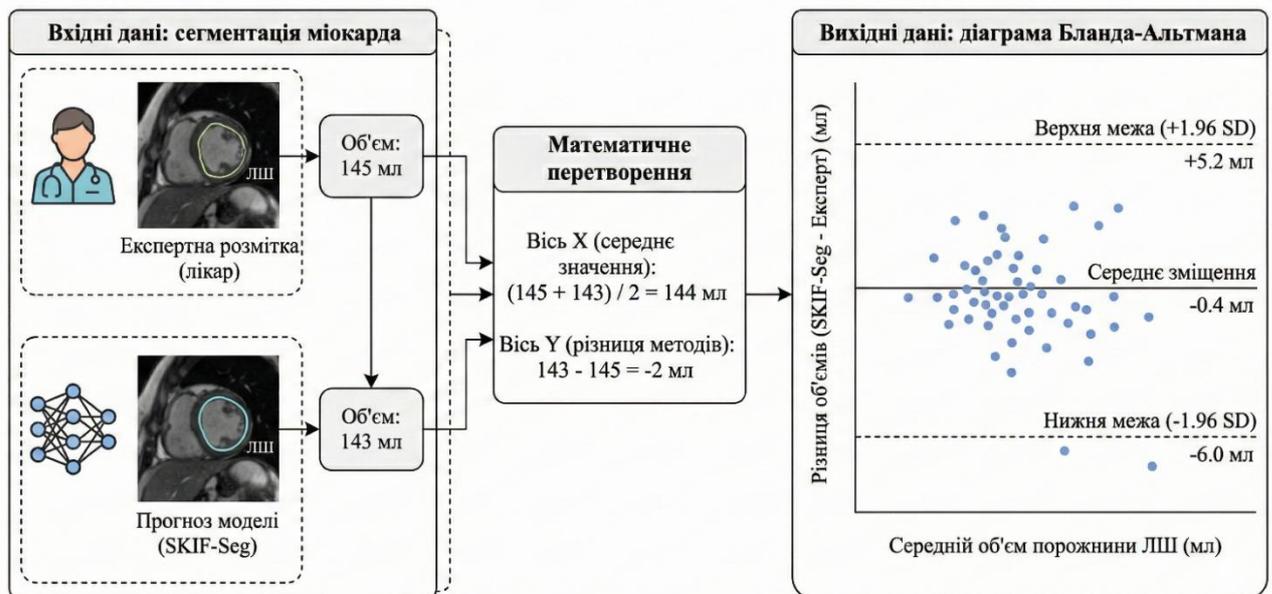


Рисунок 4.25 – Діаграма Бланда-Альтмана, що ілюструє високу клінічну узгодженість між автоматично розрахованим за допомогою масок SKIF-Seg та експертним, що розрахований лікарем вручну, об'ємом порожнини ЛШ

4.5. Комплексний аналіз результатів та обмеження запропонованих методів

Експериментальні дослідження, проведені в межах четвертого розділу, формують емпіричну базу дисертаційної роботи. Отримані результати підтверджують наукову гіпотезу дослідження: математична інтеграція верифікованих експертних знань у топологічну структуру нейронних мереж є чинником підвищення надійності, інтерпретованості та стійкості систем штучного інтелекту.

Дані зведеної табл. 4.14 демонструють, що перехід до побудови гібридних, нейро-символьних архітектур забезпечує не лише математичне покращення метрик точності, але й формує передумови для прозорої інтерпретованості рішень.

Таблиця 4.14

Комплексний аналіз обчислювальної складності для всіх розроблених модулів інтелектуальної системи

Компонент / Модель системи	Кількість параметрів, млн	Обчислюваль на складність, GFLOPs	Цільове призначення
Етап 1: Модуль дистиляції (EMTKD)			
Ансамбль 3-х вчителів (ResNet-50)	$3 \times 25,5 =$ 76,5	$3 \times 4,1 =$ 12,3	Формування м'яких міток (лише навчання)
Модель-учень (ResNet-18)	11,6	1,8	Інференс на слабких периферійних пристроях
Етап 2: Модуль оброблення природної мови (Гібридна NLI)			
Базовий кодувальник (BioELMo)	93,6	15,2	Контекстуальне розуміння синтаксису тексту
Онтологічний модуль (MultE)	12,4	0,5	Вбудовування бази знань UMLS
Етап 3: Модуль сегментації зображення (SKIF-Seg)			
Базова архітектура U-Net	31,0	65,5	Екстракція візуальних базових ознак
Механізм уваги EGA + TAAC	+ 0,8	+ 1,2	Забезпечення анатомічної топології
Етап 4: Модуль ідентифікації патологій (KI-GCN)			
GCN (2 шари)	2,4	0,1	Фінальна клінічна класифікація захворювань

Модульна мікросервісна структура системи «IDK Medical AI» створює можливості для динамічного комбінування методів обробки даних та інтеграції комплексу в госпітальні інформаційні системи без необхідності їхньої докорінної перебудови.

Результати експериментального тестування над удосконаленим EMTKD (табл. 4.3) засвідчили його високий рівень стійкості в умовах дефіциту розмічених даних. Досягнутий показник AUC-ROC на рівні 81,45 % за наявності лише 500 анотованих зразків розширює можливості розгортання моделей на нових типах сканерів без тривалого збору даних. Аналіз простору ознак (рис. 4.8) підтверджує формування доменно-інваріантних ознак.

Аналіз сегментаційних масок за розробленим методом SKIF-Seg на наборі ACDC підтвердив зменшення частки топологічних помилок (рис. 4.21). ТААС функціонує як просторовий регуляризатор, що гарантує анатомічну коректність меж Міо, що є необхідною умовою для розрахунку клінічних параметрів. Модель класифікації за методом KI-GCN продемонструвала збалансовану чутливість та специфічність (рис. 4.22), а також належний ступінь температурного калібрування (рис. 4.23).

Водночас у процесі досліджень було об'єктивно виявлено низку технічних та експлуатаційних обмежень. Аналіз швидкодії (табл. 4.1 та рис. 4.24) вказує на залежність системи від наявності апаратних графічних прискорювачів (GPU). Час обробки одного 3D-об'єму на процесорі (CPU) становить 5,3 секунди порівняно з 0,8 секунди на графічному прискорювачі CUDA, що обмежує впровадження системи на застарілому обладнанні вітчизняних лікарень.

Результати абляційного дослідження (рис. 4.12 та табл. 4.10) розкривають значну алгоритмічну складність розроблених рішень. Результативність системи досягається виключно за умови синхронного використання всіх компонентів: адаптивного зважування, SSL, доменної адаптації, EGA та ТААС. Відключення окремих модулів призводить до помітного зниження загальної точності, що свідчить про високу чутливість гіперпараметрів та ускладнює налаштування комплексу.

Для розв'язання задачі NLP гібридна нейромережева модель, що створена за удосконаленим методом OPNI, продемонструвала покращення класифікації в класі «Суперечність» завдяки використанню інструмента NegEx (рис. 4.15). Заразом, відносний приріст точності (1,4 %) окреслює концептуальні межі рекурентної

архітектури BioELMo та вказує на перспективи інтеграції онтологічних графів із генеративними LLM, з огляду на вимоги до апаратних ресурсів та проблеми контролю генеративних галюцинацій.

4.6. Висновки до розділу 4

У межах четвертого розділу спроектовано та реалізовано програмний комплекс «IDK Medical AI», що ґрунтується на принципах модульної мікросервісної архітектури. Система здійснює масштабовану обробку гетерогенних медичних даних та інтегрує алгоритми сегментації, класифікації графів та аналізу клінічних текстів. Розроблено програмні інтерфейси для завантаження даних форматів DICOM/NIfTI, тонкого налаштування параметрів мереж та візуалізації результатів.

Проведено серію експериментальних досліджень запропонованих методів на наборах даних MIMIC-CXR, ACDC та MedNLI. Валідація EMTKD зафіксувала підвищення метрики AUC-ROC на 8,8% в умовах доменного зсуву та браку розмічених даних. Модель сегментації за методом SKIF-Seg продемонструвала покращення DSC та зниження показників метрики відстані Хаусдорфа, забезпечуючи топологічну коректність масок органів. Модель класифікації за методом KI-GCN досягла точності ідентифікації патологій на рівні 94,0%.

Виконано порівняльний аналіз із сучасними аналогами та досліджено обчислювальну складність алгоритмів (GFLOPs, вимоги до VRAM). Здобуті результати підтверджують, що гібридні нейро-символьні підходи сприяють підвищенню точності діагностування, стабільності під час доменних зсувів та забезпечують клінічну інтерпретованість результатів у реальних умовах лікувальних закладів.

Основні результати розділу опубліковані у працях [29–31, 34, 35].

ВИСНОВКИ

У дисертаційній роботі розв'язано актуальну науково-прикладну задачу підвищення точності та надійності процесу прийняття рішень у медичних діагностичних комплексах через створення методів та засобів інтеграції експертних знань у моделі штучного інтелекту.

У процесі виконання дисертаційної роботи було отримано такі наукові та практичні результати:

1. Проведено системний аналіз сучасного стану методів глибокого навчання та підходів до формалізації медичних знань. Встановлено, що класичні моделі, які навчаються виключно на даних, як от підхід на основі даних, досягли межі своєї ефективності в умовах характерного для медицини дефіциту анотованих наборів та високої варіативності діагностичного обладнання. Виявлено основні опущення, зокрема «семантичний розрив» між низькорівневими ознаками та клінічними поняттями, а також проблему зсуву домену, що знижують довіру до автоматизованих систем. Обґрунтовано необхідність створення гібридних архітектур, які поєднують обчислювальну потужність нейронних мереж із верифікованими медичними знаннями (анатомічними, процедурними, онтологічними). Обмеженням існуючих підходів визнано їхню фрагментарність, тоді як запропонована концепція вимагає складнішого етапу проектування архітектури порівняно з наскрізними моделями.

2. Удосконалено метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня (EMTKD), який, на відміну від відомих аналогів, використовує динамічний ансамбль моделей-вчителів та механізм селективної фільтрації для передачі узагальненого досвіду компактній моделі-учню. Запропонований метод дав можливість подолати проблему зсуву домену: при навчанні на доволі обмеженій вибірці (500 зразків) цільового домену вдалося підвищити метрику AUC-ROC на тестовому наборі MIMIC-CXR до 81,45 %. Валідація методу продемонструвала загальний приріст метрики якості адаптації на 8,8 % порівняно з базовими методами трансферного навчання. Обмеженням методу є підвищена

обчислювальна складність на етапі навчання через необхідність тренування кількох вчителів, проте це компенсується високою швидкістю та компактністю моделі-учня під час інференсу.

3. Удосконалено метод встановлення смислових зв'язків у медичних текстах (OPNI), що інтегрує онтологічні знання з бази UMLS та аналіз тональності в архітектуру нейронної мережі. Завдяки впровадженню механізму явного кодування інформації про заперечення та семантичні зв'язки, точність інтерпретації клінічних записів на еталонному наборі MedNLI зросла до 81,14 %. Метод перевершив базові контекстуальні моделі, такі як BioELMo, зокрема за показником F1-міри, досягнувши рівня 79,85 %, що дало змогу суттєво підвищити логічну узгодженість діагностичних висновків та покращити розпізнавання суперечностей у текстах. Аналіз обмежень вказує на залежність точності методу від якості роботи інструменту MetaMap та повноти зовнішньої бази знань, що може бути джерелом помилок під час оброблення рідкісних термінів.

4. Розроблено новий метод сегментації зображень МРТ серця (SKIF-Seg), що ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги (EGA) та спеціалізованої функції втрат із топологічними обмеженнями (ТААС). Впровадження методу дало можливість гарантувати анатомічну коректність масок, суттєво зменшивши кількість артефактів типу «розрив контуру» або «острівці шуму». Метрику відстані Хаусдорфа для міокарда зменшено з 9,8 мм до 6,5 мм, а коефіцієнт Дайса для лівого шлуночка підвищено до 95,5 %, що підтверджує ефективність підходу для прецизійної морфометрії. Обмеженням методу є чутливість до налаштування вагових коефіцієнтів компонентів функції втрат та збільшення часу навчання через необхідність розрахунку карт знакових відстаней.

5. Розроблено новий метод ідентифікації патологій із використанням графової згорткової мережі (KI-GCN), який моделює складні просторові та функціональні взаємозв'язки між анатомічними структурами серця. Запропонований спосіб побудови матриці суміжності як суперпозиції просторових зв'язків та клінічних кореляцій забезпечив точність класифікації діагнозів на рівні 94,0 %. Метод перевершив базові моделі CNN за точністю на 9,0 %, водночас

забезпечуючи інтерпретованість рішень через механізм глобальної субдискретизації уваги, що дає змогу візуалізувати внесок кожного органу у фінальний діагноз. Обмеженням методу є його залежність від якості попереднього етапу сегментації: помилки у визначенні меж органів можуть транлюватися в неточні вхідні ознаки для GCN.

6. Спроектвано архітектуру інтелектуальної інформаційної системи «IDK Medical AI», яка забезпечує гнучку обробку гетерогенних медичних даних та підтримку модульної взаємодії компонентів. Архітектура включає рівень абстракції даних, високопродуктивне обчислювальне ядро та модуль інтеграції знань, що дає змогу динамічно будувати графи обчислень залежно від типу вхідної інформації. Реалізована архітектура забезпечує ефективну взаємодію між модулями сегментації, класифікації та аналізу текстів, створюючи єдине середовище для підтримки прийняття лікарських рішень. Технічним обмеженням реалізації є високі вимоги до апаратного забезпечення для забезпечення роботи системи в режимі реального часу.

7. Створено програмний комплекс «IDK Medical AI», який є практичною реалізацією розробленої інтелектуальної інформаційної системи. Практична значущість запропонованих методів емпірично підтверджена за результатами експериментального дослідження на еталонних медичних наборах даних MIMIC-SXR, ACDC та MedNLI. Інтеграція запропонованих методів дає змогу знизити часові витрати на опрацювання окремих клінічних випадків і підвищити точність ідентифікації патологій серця зображенням МРТ унаслідок формування обґрунтованої альтернативної оцінки, так званої лікарської «другої думки». Аналіз результатів підтверджує стабільність функціонування системи та її стійкість до варіативності вхідних даних, що свідчить про технічну готовність комплексу до тестування в клінічній практиці. Водночас для подальшого масштабування системи для діагностування ширшого спектра захворювань виникне потреба у відповідному поповненні інтегрованих баз знань.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Synthesis of convolutional neural network architectures for biomedical image classification / O. Berezsky et al. *Biomedical Signal Processing and Control*. 2024. Vol. 95. P. 106325. URL: <https://doi.org/10.1016/j.bspc.2024.106325> (date of access: 10.12.2025).
2. Berezsky O. M., Liashchynskyi P. B. Method of generative-adversarial networks searching architectures for biomedical images synthesis. *Radio Electronics, Computer Science, Control*. 2024. No. 1. P. 104. URL: <https://doi.org/10.15588/1607-3274-2024-1-10> (date of access: 10.12.2025).
3. An approach toward automatic specific diagnosis of breast cancer based on an immunohistochemical image / O. Berezsky et al. *Journal of Imaging*. 2023. Vol. 9, no. 1. P. 12. URL: <https://doi.org/10.3390/jimaging9010012> (date of access: 10.12.2025).
4. Improvement of the ANN-based prediction technology for extremely small biomedical data analysis / I. Izonin et al. *Technologies*. 2024. Vol. 12, no. 7. P. 112. URL: <https://doi.org/10.3390/technologies12070112> (date of access: 10.12.2025).
5. A cascade ensemble-learning model for the deployment at the edge: case on missing IoT data recovery in environmental monitoring systems / I. Izonin et al. *Frontiers in Environmental Science*. 2023. Vol. 11. URL: <https://doi.org/10.3389/fenvs.2023.1295526> (date of access: 10.12.2025).
6. Algorithmization and optimization models of patient-centric rehabilitation programs* / D. V. Vakulenko et al. *Cybernetics and Systems Analysis*. 2024. URL: <https://doi.org/10.1007/s10559-024-00711-5> (date of access: 10.12.2025).
7. Digital health systems: ontology-based universal dialog service for hybrid e-rehabilitation activities support / O. Palagin et al. *2023 IEEE 12th International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*, Dortmund, Germany, 7–9 September 2023. 2023. URL: <https://doi.org/10.1109/idaacs58523.2023.10348639> (date of access: 10.12.2025).

8. Avrunin O. Using a priori data for segmentation anatomical structures of the brain. *PRZEGLĄD ELEKTROTECHNICZNY*. 2017. Vol. 1, no. 5. P. 104–107. URL: <https://doi.org/10.15199/48.2017.05.20> (date of access: 10.12.2025).
9. Possibilities of automated diagnostics of odontogenic sinusitis according to the computer tomography data / O. G. Avrunin et al. *Sensors*. 2021. Vol. 21, no. 4. P. 1198. URL: <https://doi.org/10.3390/s21041198> (date of access: 10.12.2025).
10. Machine learning for medical imaging / B. J. Erickson et al. *Radiographics*. 2017. Vol. 37, no. 2. P. 505–515. URL: <https://doi.org/10.1148/rg.2017160130>
11. A survey on deep learning in medical image analysis / G. Litjens et al. *Medical Image Analysis*. 2017. Vol. 42. P. 60–88. URL: <https://doi.org/10.1016/j.media.2017.07.005> (date of access: 11.12.2025).
12. Dermatologist-level classification of skin cancer with deep neural networks / A. Esteva et al. *Nature*. 2017. Vol. 542, no. 7639. P. 115–118. URL: <https://doi.org/10.1038/nature21056> (date of access: 11.12.2025).
13. Ronneberger O., Fischer P., Brox T. U-Net: convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Cham, 2015. Vol. 9351 : Lecture Notes in Computer Science. P. 234–241. URL: https://doi.org/10.1007/978-3-319-24574-4_28 (date of access: 29.01.2026).
14. 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> (date of access: 11.12.2025).
15. Sirocchi C., Bogliolo A., Montagna S. Medical-informed machine learning: Integrating prior knowledge into medical decision systems. *BMC Medical Informatics and Decision Making*. 2024. Vol. 24, no. 4. P. 186. URL: <https://doi.org/10.1186/s12911-024-02582-4> (date of access: 11.12.2025).
16. MEDKD: enhancing medical image classification with multiple expert decoupled knowledge distillation for long-tail data / F. Zhang et al. *Machine Learning in Medical Imaging -- MLMI 2023*. Cham, 2024. Vol. 14349 : Lecture Notes in Computer

Science. P. 314–324. URL: https://doi.org/10.1007/978-3-031-45676-3_32 (date of access: 12.12.2025).

17. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017. Vol. 60, no. 6. P. 84–90. URL: <https://doi.org/10.1145/3065386> (date of access: 08.04.2025).

18. Explainable knowledge distillation for on-device chest X-ray classification / C. Termritthikun et al. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. 2024. Vol. 21, no. 4. P. 846–856. URL: <https://doi.org/10.1109/TCBB.2023.3272333> (date of access: 11.12.2025).

19. Öksüz C., Urhan O., Güllü M. K. An integrated convolutional neural network with attention guidance for improved performance of medical image classification. *Neural Computing and Applications*. 2023. Vol. 36, no. 4. P. 2067–2099. URL: <https://doi.org/10.1007/s00521-023-09164-x> (date of access: 12.12.2025).

20. Graph attention networks / P. Veličković et al. Ithaca, NY, USA : Cornell University, 2018. 12 p. (Preprint. Cornell University ; arXiv.1710.10903). URL: <https://doi.org/10.48550/arXiv.1710.10903> (date of access: 13.12.2025).

21. An end-to-end deep learning architecture for graph classification / M. Zhang et al. *Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence*. 2018. Vol. 31, no. 1. P. 4438–4445. URL: <https://doi.org/10.1609/aaai.v32i1.11782> (date of access: 11.12.2025).

22. Huang Z., Li B., Yin J. Knowledge graph embedding via multiplicative interaction. *Proceedings of the 2nd International Conference on Innovation in Artificial Intelligence* : Proceedings, Shanghai, China, 9–12 March 2018. New York, New York, USA, 2018. P. 138–142. URL: <https://doi.org/10.1145/3194206.3194227> (date of access: 13.12.2025).

23. Incorporating domain knowledge into medical NLI using knowledge graphs / S. Sharma et al. *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)* : Proceedings, Hong Kong, China, 3–7 November

2019. Stroudsburg, PA, USA, 2019. P. 6092–6097. URL: <https://doi.org/10.18653/v1/d19-1631> (date of access: 14.12.2025).

24. 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. Järvis, Tallinn: Teadmus OÜ, 2024, P. 204–216. URL: <https://conference.euas.eu/2023/wp-content/uploads/2024/03/Monograph2023.pdf>* (date of access: 11.12.2025).

25. Чабан О. Р. Метод інтеграції доменних знань на основі графових нейронних мереж для сегментації зображення МРТ серця. *Вісник Хмельницького національного університету. Серія: технічні науки.* 2025. Т. 361, № 1. С. 452–457. URL: <https://doi.org/10.31891/2307-5732-2026-361-62> (дата звернення: 29.01.2026).

26. Чабан О. Р. Метод поєднання контекстних векторних представлень слів із векторним поданням медичного домену. *Вимірювальна та обчислювальна техніка в технологічних процесах.* 2025. Вип. 82, № 2. С. 297–301. URL: <https://doi.org/10.31891/2219-9365-2025-82-42> (дата звернення: 11.12.2025).

27. Chaban O., Manziuk E., Radiuk P. Method of adaptive knowledge distillation from multi-teacher to student deep learning models. *Journal of Edge Computing.* 2025. Vol. 4, no. 2. P. 159–178. URL: <https://doi.org/10.55056/jec.978> (date of access: 11.12.2025).

28. 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: 11.12.2025).

29. Intelligent information system for knowledge integration into artificial intelligence models / O. Chaban et al. *Proceedings of the 2nd International Workshop on Advanced Applied Information Technologies: AI & DSS: CEUR-Workshop Proceedings, Khmelnytskyi, Ukraine, Zilina, Slovakia, 5 December 2025. Aachen, 2026. P. 145–161. URL: <https://ceur-ws.org/Vol-4163/paper13.pdf>* (date of access: 07.02.2026).

30. Knowledge-integrated graph networks for interpretable cardiac MRI analysis / O. Chaban et al. *Proceedings of the 8th international Conference on Informatics & Data-Driven Medicine* : CEUR-Workshop Proceedings, Lviv, Ukraine, 19–20 November 2025. Aachen, 2025. P. 1–15.

31. 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, Ukraine, 4 April 2025. Aachen, 2025. P. 42–57. URL: <https://ceur-ws.org/Vol-3943/paper09.pdf> (date of access: 11.12.2025).

32. Чабан О. Р., Манзюк Е. А. Підхід до інтегрування експертних знань в модель U-Net для сегментування зображень МРТ серця. *Нейромережні технології та їх застосування НМТЗ-2024* : матеріали ХХІІ Міжнар. наук. конф., м. Краматорськ-Вінниця-Тернопіль, 11–12 груд. 2024 р. Краматорськ, 2024. С. 145–149. URL: <https://elar.khmnu.edu.ua/handle/123456789/17766> (дата звернення: 11.12.2025).

33. Чабан О. Р., Манзюк Е. А. Метод дистилляції знань від моделей-вчителів до моделі учня глибокого навчання. *Актуальні проблеми комп'ютерних наук АПКН-2024* : матеріали ХVІ Всеукр. науково-практ. конф., м. Хмельницький, 15–16 листоп. 2024 р. Хмельницький, 2024. С. 196–199. URL: <https://elar.khmnu.edu.ua/handle/123456789/17767> (дата звернення: 11.12.2025).

34. Chaban O., Manziuk E. Enhancing medical NLI with integrated domain knowledge and sentiment analysis. *Proceedings of the 12th International Conference Information Control Systems & Technologies (ICST 2024)* : CEUR-Workshop Proceedings, Odesa, Ukraine, 23–25 September 2024. Aachen, 2024. P. 262–272. URL: <https://ceur-ws.org/Vol-3790/paper23.pdf> (date of access: 11.12.2025).

35. Комп'ютерна програма “Інтелектуальна інформаційна система інтеграції знань в моделі штучного інтелекту медичних діагностичних комплексів” : а. с. 141364 Україна : CR3113021225 / О. Р. Чабан, Е. А. Манзюк, П. М. Радюк. № с202508817 ; заявл. 10.10.2025 ; опубл. 31.01.2026, Бюл. № 97. 20 с. URL: <https://sis.nipo.gov.ua/uk/search/detail/1897624/> (дата звернення: 01.02.2026).

36. Zhang C., Patras P., Haddadi H. Deep learning in mobile and wireless networking: a survey. *IEEE Communications Surveys & Tutorials*. 2019. Vol. 21, no. 3. P. 2224–2287. URL: <https://doi.org/10.1109/COMST.2019.2904897> (date of access: 11.12.2025).

37. Survey of deep learning in breast cancer image analysis / T. G. Debelee et al. *Evolving Systems*. 2020. Vol. 11, no. 1. P. 143–163. URL: <https://doi.org/10.1007/s12530-019-09297-2> (date of access: 11.12.2025).

38. Breast lesion detection scheme for low gadolinium dose DCE-MRI using radon cumulative distribution transform and domain transfer: preliminary results / J. Lee et al. *Computer-Aided Diagnosis*, San Diego, CA, USA, 18–23 February 2024 / ed. by S. M. Astley, W. Chen. 2024. P. 129271. URL: <https://doi.org/10.1117/12.3004216> (date of access: 12.12.2025).

39. Deep neural networks improve radiologists' performance in breast cancer screening / N. Wu et al. *IEEE Transactions on Medical Imaging*. 2020. Vol. 39, no. 4. P. 1184–1194. URL: <https://doi.org/10.1109/TMI.2019.2945514> (date of access: 11.12.2025).

40. DeepLung: deep 3D dual path nets for automated pulmonary nodule detection and classification / W. Zhu et al. *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)* : Proceedings, Lake Tahoe, NV, USA, 12–15 March 2018. New York City, NY, USA, 2018. P. 673–681. URL: <https://doi.org/10.1109/wacv.2018.00079> (date of access: 14.12.2025).

41. Automatic classification of pulmonary perifissural nodules in computed tomography using an ensemble of 2D views and a convolutional neural network out-of-the-box / F. Ciompi et al. *Medical Image Analysis*. 2015. Vol. 26, no. 1. P. 195–202. URL: <https://doi.org/10.1016/j.media.2015.08.001> (date of access: 11.12.2025).

42. CDAM-Net: channel shuffle dual attention based multi-scale CNN for efficient glaucoma detection using fundus images / D. Das et al. *Engineering Applications of Artificial Intelligence*. 2024. Vol. 133. P. 108454. URL: <https://doi.org/10.1016/j.engappai.2024.108454> (date of access: 12.12.2025).

43. A transfer learning-based multimodal neural network combining metadata and multiple medical images for glaucoma type diagnosis / Y. Li et al. *Scientific Reports*. 2023. Vol. 13. P. 12076. URL: <https://doi.org/10.1038/s41598-022-27045-6> (date of access: 11.12.2025).

44. Novel mixed domain hand-crafted features for skin disease recognition using multi-headed CNN / A. Kumar et al. *IEEE Transactions on Instrumentation and Measurement*. 2024. Vol. 73. P. 1–13. URL: <https://doi.org/10.1109/tim.2024.3370772> (date of access: 12.12.2025).

45. Generalizing from a few examples: a survey on few-shot learning / Y. Wang et al. *ACM Computing Surveys*. 2020. Vol. 53, no. 3. P. 1–34. URL: <https://doi.org/10.1145/3386252> (date of access: 11.12.2025).

46. Halevy A., Norvig P., Pereira F. The unreasonable effectiveness of data. *IEEE Intelligent Systems*. 2009. Vol. 24, no. 2. P. 8–12. URL: <https://doi.org/10.1109/MIS.2009.36> (date of access: 11.12.2025).

47. Source-free unsupervised domain adaptation: a survey / Y. Fang et al. *Neural Networks*. 2024. Vol. 174. P. 106230. URL: <https://doi.org/10.1016/j.neunet.2024.106230> (date of access: 11.12.2025).

48. ChestX-Ray8: hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases / X. Wang et al. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) : Proceedings*, Honolulu, HI, USA, 21–26 July 2017. New York City, NY, USA, 2017. P. 3462–3471. URL: <https://doi.org/10.1109/cvpr.2017.369> (date of access: 28.01.2026).

49. CheXpert: a large chest radiograph dataset with uncertainty labels and expert comparison / J. Irvin et al. *Proceedings of the Thirty-Third AAAI Conference on Artificial Intelligence and Thirty-First Innovative Applications of Artificial Intelligence Conference and Ninth AAAI Symposium on Educational Advances in Artificial Intelligence*. Honolulu, HI, USA, 2019. Vol. 33, no. 01, P. 590–597. URL: <https://doi.org/10.1609/aaai.v33i01.3301590> (date of access: 11.12.2025).

50. PadChest: a large chest X-ray image dataset with multi-label annotated reports / A. Bustos et al. *Medical Image Analysis*. 2020. Vol. 66. P. 101797. URL: <https://doi.org/10.1016/j.media.2020.101797> (date of access: 11.12.2025).
51. DeepLesion: automated mining of large-scale lesion annotations and universal lesion detection with deep learning / K. Yan et al. *Journal of Medical Imaging*. 2018. Vol. 5, no. 3. P. 036501. URL: <https://doi.org/10.1117/1.JMI.5.3.036501> (date of access: 11.12.2025).
52. MIMIC-CXR: a publicly available database of chest radiographs with free-text reports / A. E. W. Johnson et al. *Scientific Data*. 2019. Vol. 6. P. 317. URL: <https://doi.org/10.1038/s41597-019-0322-0> (date of access: 11.12.2025).
53. Extreme cardiac MRI analysis under respiratory motion: results of the CMRxMotion challenge / K. Wang et al. *Medical Image Analysis*. 2025. Vol. 109. P. 103883. URL: <https://doi.org/10.1016/j.media.2025.103883> (date of access: 12.12.2025).
54. CMRxRecon: a publicly available k-space dataset and benchmark to advance deep learning for cardiac MRI / C. Wang et al. *Scientific Data*. 2024. Vol. 11, no. 1. P. 687. URL: <https://doi.org/10.1038/s41597-024-03525-4> (date of access: 11.12.2025).
55. 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: 11.12.2025).
56. The autism brain imaging data exchange: towards a large-scale evaluation of the intrinsic brain architecture in autism / A. Di Martino et al. *Molecular Psychiatry*. 2014. Vol. 19, no. 6. P. 659–667. URL: <https://doi.org/10.1038/mp.2013.78> (date of access: 11.12.2025).
57. The Alzheimer’s Disease Neuroimaging Initiative 3: continued innovation for clinical trial improvement / M. W. Weiner et al. *Alzheimer’s & Dementia*. 2017. Vol. 13, no. 5. P. 561–571. URL: <https://doi.org/10.1016/j.jalz.2016.10.006> (date of access: 11.12.2025).

58. Low-dose computed tomography perceptual image quality assessment / W. Lee et al. *Medical Image Analysis*. 2024. Vol. 99. P. 103343. URL: <https://doi.org/10.1016/j.media.2024.103343> (date of access: 12.12.2025).

59. Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge / S. Bakas et al. Ithaca, NY, USA : Cornell University, 2018. 49 p. (Preprint. Cornell University ; arXiv:1811.02629). URL: <https://doi.org/10.48550/arXiv.1811.02629> (date of access: 12.12.2025).

60. Elbatel M., Martínez M., Li X. FoPro-KD: Fourier prompted effective knowledge distillation for long-tailed medical image recognition. *IEEE Transactions on Medical Imaging*. 2024. Vol. 43, no. 3. P. 954–965. URL: <https://doi.org/10.1109/TMI.2023.3327428> (date of access: 11.12.2025).

61. Automatic detection of cerebral microbleeds from MR images via 3D convolutional neural networks / Q. Dou et al. *IEEE Transactions on Medical Imaging*. 2016. Vol. 35, no. 5. P. 1182–1195. URL: <https://doi.org/10.1109/TMI.2016.2528129> (date of access: 11.12.2025).

62. Karimi D., Salcudean S. E. Reducing the Hausdorff distance in medical image segmentation with convolutional neural networks. *IEEE Transactions on Medical Imaging*. 2020. Vol. 39, no. 2. P. 499–513. URL: <https://doi.org/10.1109/TMI.2019.2930068> (date of access: 11.12.2025).

63. Kingma D. P., Ba J. Adam: a method for stochastic optimization. *3rd International Conference on Learning Representations (ICLR 2015)* : Proceedings, San Diego, CA, USA, 7–9 May 2015 / ed. by Y. Bengio, Y. LeCun. 2015. P. 1–15. URL: <https://doi.org/10.48550/arXiv.1412.6980> (date of access: 12.12.2025).

64. Zhang Z., Yang L., Zheng Y. Translating and segmenting multimodal medical volumes with cycle- and shape-consistency generative adversarial network. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Salt Lake City, UT, 18–23 June 2018. New York City, NY, USA, 2018. P. 9242–9251. URL: <https://doi.org/10.1109/cvpr.2018.00963> (date of access: 14.12.2025).

65. Domain-adversarial training of neural networks / Y. Ganin et al. *Journal of Machine Learning Research*. 2016. Vol. 17, no. 1. P. 2096–2030. URL: <https://dl.acm.org/doi/10.5555/2946645.2946704> (date of access: 11.12.2025).

66. How transferable are features in deep neural networks? / J. Yosinski et al. *Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 2 : Proceedings*, Montreal, Canada, 8–13 December 2014. Cambridge, MA, USA, 2014. P. 3320–3328. URL: <https://dl.acm.org/doi/10.5555/2969033.2969197> (date of access: 12.12.2025).

67. Medical image classification: knowledge transfer via residual U-Net and vision transformer-based teacher-student model with knowledge distillation / Y. Song et al. *Journal of Visual Communication and Image Representation*. 2024. Vol. 102. P. 104212. URL: <https://doi.org/10.1016/j.jvcir.2024.104212> (date of access: 11.12.2025).

68. Transfer learning with CNNs for efficient prostate cancer and benign prostatic hyperplasia detection in transrectal ultrasound images / T.-L. Huang et al. *Scientific Reports*. 2023. Vol. 13. P. 21849. URL: <https://doi.org/10.1038/s41598-023-49159-1> (date of access: 11.12.2025).

69. ProCUSNet: prostate cancer detection on b-mode transrectal ultrasound using artificial intelligence for targeting during prostate biopsies / M. Rusu et al. *European Urology Oncology*. 2025. Vol. 8, no. 2. P. 477–485. URL: <https://doi.org/10.1016/j.euo.2024.12.012> (date of access: 10.12.2025).

70. Knowledge distillation: a survey / J. Gou et al. *International Journal of Computer Vision*. 2021. Vol. 129, no. 6. P. 1789–1819. URL: <https://doi.org/10.1007/s11263-021-01453-z> (date of access: 11.12.2025).

71. Najjar R. Redefining radiology: a review of artificial intelligence integration in medical imaging. *Diagnostics*. 2023. Vol. 13, no. 17. P. 2760. URL: <https://doi.org/10.3390/diagnostics13172760> (date of access: 12.12.2025).

72. Attention-guided curriculum learning for weakly supervised classification and localization of thoracic diseases on chest radiographs / Y. Tang et al. *Machine Learning in Medical Imaging -- MLMI 2018*. Lecture Notes in Computer Science. Vol.

11046. Springer, Cham. 2018. P. 249–258. URL: https://doi.org/10.1007/978-3-030-00919-9_29 (date of access: 11.12.2025).

73. A comprehensive survey on integrating large language models with knowledge-based methods / W. Yang et al. *Knowledge-Based Systems*. 2025. Vol. 318. P. 113503. URL: <https://doi.org/10.1016/j.knosys.2025.113503> (date of access: 10.12.2025).

74. Ultrasound prostate segmentation based on multidirectional deeply supervised V-Net / Y. Lei et al. *Medical Physics*. 2019. Vol. 46, no. 7. P. 3194–3206. URL: <https://doi.org/10.1002/mp.13577> (date of access: 11.12.2025).

75. Lu C., Zhang J., Liu R. Deep learning-based image classification for integrating pathology and radiology in AI-assisted medical imaging. *Scientific Reports*. 2025. Vol. 15, no. 1. P. 27029. URL: <https://doi.org/10.1038/s41598-025-07883-w> (date of access: 12.12.2025).

76. Fusing texture, shape and deep model-learned information at decision level for automated classification of lung nodules on chest CT / Y. Xie et al. *Information Fusion*. 2018. Vol. 42. P. 102–110. URL: <https://doi.org/10.1016/j.inffus.2017.10.005> (date of access: 11.12.2025).

77. A novel hybridized feature extraction approach for lung nodule classification based on transfer learning technique / P. M. Bruntha et al. *Journal of Medical Physics*. 2022. Vol. 47, no. 1. P. 1–9. URL: https://doi.org/10.4103/jmp.jmp_61_21 (date of access: 12.12.2025).

78. The effects of perinodular features on solid lung nodule classification / J. L. L. Calheiros et al. *Journal of Digital Imaging*. 2021. Vol. 34, no. 4. P. 798–810. URL: <https://doi.org/10.1007/s10278-021-00453-2> (date of access: 12.12.2025).

79. Attention U-Net: learning where to look for the pancreas / O. Oktay et al. Ithaca, NY, USA : Cornell University, 2018. 10 p. (Preprint. Cornell University ; arXiv.1804.039). URL: <https://doi.org/10.48550/arXiv.1804.03999> (date of access: 12.12.2025).

80. Zhang D., Yuan X., Zhang P. Interpretable deep learning for automatic diagnosis of 12-lead electrocardiogram. *iScience*. 2021. Vol. 24, no. 4. P. 102373. URL: <https://doi.org/10.1016/j.isci.2021.102373> (date of access: 11.12.2025).

81. Brauwerters G., Frasinca F. A general survey on attention mechanisms in deep learning. *IEEE Transactions on Knowledge and Data Engineering*. 2023. Vol. 35, no. 4. P. 3279–3298. URL: <https://doi.org/10.1109/TKDE.2021.3126456> (date of access: 11.12.2025).

82. Bian W., Jang A., Liu F. Multi-task magnetic resonance imaging reconstruction using meta-learning. *Magnetic Resonance Imaging*. 2024. Vol. 116. P. 110278. URL: <https://doi.org/10.1016/j.mri.2024.110278> (date of access: 30.11.2025).

83. 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: 12.12.2025).

84. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations (ICLR 2015)* : Conference Track Proceedings, San Diego, CA, USA, 7–9 May 2015 / ed. by Y. Bengio, Y. LeCun. 2015. P. 1–14. URL: <https://doi.org/10.48550/arXiv.1409.1556> (date of access: 08.04.2025).

85. Deep residual learning for image recognition / K. He et al. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Las Vegas, NV, USA, 27–30 June 2016. New York, NY, USA, 2016. P. 770–778. URL: <https://doi.org/10.1109/cvpr.2016.90> (date of access: 11.04.2025).

86. Densely connected convolutional networks / G. Huang et al. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Honolulu, HI, USA, 21–26 July 2017. New York, NY, USA, 2017. P. 2261–2269. URL: <https://doi.org/10.1109/cvpr.2017.243> (date of access: 02.05.2025).

87. CNN-based diagnosis models for canine ulcerative keratitis / J. Y. Kim et al. *Scientific Reports*. 2019. Vol. 9. P. 14209. URL: <https://doi.org/10.1038/s41598-019-50437-0> (date of access: 11.12.2025).

88. CANet: cross-disease attention network for joint diabetic retinopathy and diabetic macular edema grading / X. Li et al. *IEEE Transactions on Medical Imaging*. 2020. Vol. 39, no. 5. P. 1483–1493. URL: <https://doi.org/10.1109/TMI.2019.2951844> (date of access: 11.12.2025).

89. 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: 11.12.2025).

90. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation / M. Z. Alom et al. Ithaca, NY, USA : Cornell University, 2018. 12 p. (Preprint. Cornell University ; arXiv.1802.06955). URL: <https://doi.org/10.48550/arXiv.1802.06955> (date of access: 29.01.2026).

91. Brain tumor segmentation with deep neural networks / M. Havaei et al. *Medical Image Analysis*. 2017. Vol. 35. P. 18–31. URL: <https://doi.org/10.1016/j.media.2016.05.004> (date of access: 11.12.2025).

92. Magadza T., Viriri S. Deep learning for brain tumor segmentation: a survey of state-of-the-art. *Journal of Imaging*. 2021. Vol. 7, no. 2. P. 19. URL: <https://doi.org/10.3390/jimaging7020019> (date of access: 11.12.2025).

93. Location sensitive deep convolutional neural networks for segmentation of white matter hyperintensities / M. Ghafoorian et al. *Scientific Reports*. 2017. Vol. 7. P. 5110. URL: <https://doi.org/10.1038/s41598-017-05300-5> (date of access: 11.12.2025).

94. Richter L., Fetit A. E. Accurate segmentation of neonatal brain MRI with deep learning. *Frontiers in Neuroinformatics*. 2022. Vol. 16. P. 1006532. URL: <https://doi.org/10.3389/fninf.2022.1006532> (date of access: 11.12.2025).

95. DAGAN: deep de-aliasing generative adversarial networks for fast compressed sensing MRI reconstruction / G. Yang et al. *IEEE Transactions on Medical Imaging*. 2018. Vol. 37, no. 6. P. 1310–1321. URL: <https://doi.org/10.1109/TMI.2017.2785879> (date of access: 11.12.2025).

96. Conditional random fields as recurrent neural networks / S. Zheng et al. *Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV)* : Proceedings, Santiago, Chile, 7–13 December 2015. New York, NY, USA, 2015. P. 1529–1537. URL: <https://doi.org/10.1109/ICCV.2015.179> (date of access: 29.01.2026).

97. Multi-label annotation of text reports from computed tomography of the chest, abdomen, and pelvis using deep learning / V. M. D'Anniballe et al. *BMC Medical Informatics and Decision Making*. 2022. Vol. 22, no. 1. P. 102. URL: <https://doi.org/10.1186/s12911-022-01843-4> (date of access: 29.01.2026).

98. Thyroid nodule classification in ultrasound imaging using deep transfer learning / Y. Xu et al. *BMC Cancer*. 2025. Vol. 25. P. 544. URL: <https://doi.org/10.1186/s12885-025-13917-3> (date of access: 11.12.2025).

99. Alruwaili M., Gouda W. Automated breast cancer detection models based on transfer learning. *Sensors*. 2022. Vol. 22, no. 3. P. 876. URL: <https://doi.org/10.3390/s22030876> (date of access: 29.01.2026).

100. Robust cross-modal medical image translation via diffusion model and knowledge distillation / Y. Xia et al. *2024 International Joint Conference on Neural Networks (IJCNN) : Proceedings, Yokohama, Japan, 30 June – 5 July 2024*. New York City, NY, USA, 2024. P. 1–8. URL: <https://doi.org/10.1109/ijcnn60899.2024.10650498> (date of access: 29.01.2026).

101. Multiple teachers-meticulous student: a domain adaptive meta-knowledge distillation model for medical image classification / S. Nabavi et al. *Medical Physics*. 2026. Vol. 53, no. 2. P. 70350. URL: <https://doi.org/10.1002/mp.70350> (date of access: 16.02.2026).

102. Automatic multi-class cardiovascular magnetic resonance image quality assessment using unsupervised domain adaptation in spatial and frequency domains / S. Nabavi et al. *Journal of Innovations in Computer Science and Engineering (JICSE)*. 2025. Vol. 3, no. 1. P. 22–35. URL: <https://doi.org/10.48308/jicse.2025.239094.1048> (date of access: 29.01.2026).

103. Guan H., Liu M. Domain adaptation for medical image analysis: a survey. *IEEE Transactions on Biomedical Engineering*. 2022. Vol. 69, no. 3. P. 1173–1185. URL: <https://doi.org/10.1109/TBME.2021.3117407> (date of access: 11.12.2025).

104. Dong W., Du B., Xu Y. Shape-intensity knowledge distillation for robust medical image segmentation. *Frontiers of Computer Science*. 2025. Vol. 19,

no. 9. P. 199705. URL: <https://doi.org/10.1007/s11704-024-40462-2> (date of access: 29.01.2026).

105. PA-Seg: learning from point annotations for 3D medical image segmentation using contextual regularization and cross knowledge distillation / S. Zhai et al. *IEEE Transactions on Medical Imaging*. 2023. Vol. 42, no. 8. P. 2235–2246. URL: <https://doi.org/10.1109/TMI.2023.3245068> (date of access: 11.12.2025).

106. ViT-FRD: a vision transformer model for cardiac MRI image segmentation based on feature recombination distillation / C. Fan et al. *IEEE Access*. 2023. Vol. 11. P. 129763–129772. URL: <https://doi.org/10.1109/ACCESS.2023.3302522> (date of access: 11.12.2025).

107. Black-box domain adaptative cell segmentation via multi-source distillation / X. Wang et al. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2023*. Cham, 2023. Vol. 14220 : Lecture Notes in Computer Science. P. 749–758. URL: https://doi.org/10.1007/978-3-031-43907-0_71 (date of access: 29.01.2026).

108. MulGT: multi-task graph-transformer with task-aware knowledge injection and domain knowledge-driven pooling for whole slide image analysis / W. Zhao et al. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2023. Vol. 37, no. 3. P. 3606–3614. URL: <https://doi.org/10.1609/aaai.v37i3.25471> (date of access: 29.01.2026).

109. A multi-task learning framework for automated segmentation and classification of breast tumors from ultrasound images / J. Chowdary et al. *Ultrasonic Imaging*. 2022. Vol. 44, no. 1. P. 3–12. URL: <https://doi.org/10.1177/01617346221075769> (date of access: 11.12.2025).

110. Multimodal classification of Alzheimer’s disease and mild cognitive impairment using custom MKSCDDL kernel over CNN with transparent decision-making for explainable diagnosis / V. Adarsh et al. *Scientific Reports*. 2024. Vol. 14. P. 1774. URL: <https://doi.org/10.1038/s41598-024-52185-2> (date of access: 11.12.2025).

111. Öksüz C., Urhan O., Güllü M. K. An integrated convolutional neural network with attention guidance for improved performance of medical image classification.

Neural Computing and Applications. 2023. Vol. 36, no. 4. P. 2067–2099. URL: <https://doi.org/10.1007/s00521-023-09164-x> (date of access: 25.05.2025).

112. Towards A relation extractor nested u-architecture for accurate pulmonary airway segmentation in CT images / G. Ding et al. *ICCCV 2022: 2022 The 5th International Conference on Control and Computer Vision* : Proceedings, Xiamen, China, 19–21 August 2022. New York, NY, USA, 2022. P. 29–35. URL: <https://doi.org/10.1145/3561613.3561618> (date of access: 13.12.2025).

113. MommiNet: mammographic multi-view mass identification networks / Z. Yang et al. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2020*. Cham, 2020. Vol. 12266 : Lecture Notes in Computer Science. P. 200–210. URL: https://doi.org/10.1007/978-3-030-59725-2_20 (date of access: 13.12.2025).

114. MommiNet-v2: multi-view mammographic mass identification network for lesion detection and classification / Y. Tian et al. *Medical Image Analysis*. 2021. Vol. 71. P. 102204. URL: <https://doi.org/10.1016/j.media.2021.102204> (date of access: 11.12.2025).

115. Deep learning model for breast cancer diagnosis based on bilateral asymmetrical detection (BilAD) in digital breast tomosynthesis images / D. Shimokawa et al. *Radiological Physics and Technology*. 2022. Vol. 16, no. 1. P. 20–27. URL: <https://doi.org/10.1007/s12194-022-00686-y> (date of access: 13.12.2025).

116. BERT: Pre-training of deep bidirectional transformers for language understanding / J. Devlin et al. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*. Minneapolis, MN, USA, 2019. P. 4171–4186. URL: <https://doi.org/10.18653/v1/N19-1423> (date of access: 11.12.2025).

117. BioBERT: a pre-trained biomedical language representation model for biomedical text mining / J. Lee et al. *Bioinformatics*. 2020. Vol. 36, no. 4. P. 1234–1240. URL: <https://doi.org/10.1093/bioinformatics/btz682> (date of access: 11.12.2025).

118. TieNet: text-image embedding network for common thorax disease classification and reporting in chest X-rays / X. Wang et al. *2018 IEEE/CVF Conference*

on *Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Salt Lake City, UT, 18–23 June 2018. New York City, NY, USA, 2018. P. 9049–9058. URL: <https://doi.org/10.1109/cvpr.2018.00943> (date of access: 13.12.2025).

119. Gajbhiye A., Moubayed N. A., Bradley S. ExBERT: an external knowledge enhanced BERT for natural language inference. *Artificial Neural Networks and Machine Learning – ICANN 2021*. Cham, 2021. Vol. 12895 : Lecture Notes in Computer Science. P. 460–472. URL: https://doi.org/10.1007/978-3-030-86383-8_37 (date of access: 13.12.2025).

120. GCNExplainer: generating explanations for graph neural networks / R. Ying et al. *Proceedings of the 33rd International Conference on Neural Information Processing Systems* : Proceedings, Vancouver, Canada, 8–14 December 2019. Red Hook, NY, USA, 2019. P. 9244–9255. URL: <https://dl.acm.org/doi/10.5555/3454287.3455116> (date of access: 13.12.2025).

121. Patient-centric knowledge graphs: a survey of current methods, challenges, and applications / H. S. Al Khatib et al. *Frontiers in Artificial Intelligence*. 2024. Vol. 7. P. 1388479. URL: <https://doi.org/10.3389/frai.2024.1388479> (date of access: 13.12.2025).

122. When radiology report generation meets knowledge graph / Y. Zhang et al. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020. Vol. 34, no. 07. P. 12910–12917. URL: <https://doi.org/10.1609/aaai.v34i07.6989> (date of access: 11.12.2025).

123. Leveraging medical knowledge graphs into large language models for diagnosis prediction: Design and application study / Y. Gao et al. *JMIR AI*. 2025. Vol. 4. P. e58670. URL: <https://doi.org/10.2196/58670> (date of access: 11.12.2025).

124. Hierarchical graph representation learning with differentiable pooling / R. Ying et al. *Proceedings of the 32nd International Conference on Neural Information Processing Systems* : Proceedings, Montréal, Canada, 3–8 December 2018. Red Hook, NY, USA, 2018. P. 4805–4815. URL: <https://dl.acm.org/doi/10.5555/3327345.3327389> (date of access: 13.12.2025).

125. Semi-supervised classification of graph convolutional networks with Laplacian rank constraints / H. Zhang et al. *Neural Processing Letters*. 2022. Vol. 54, no. 4. P. 2645–2656. URL: <https://doi.org/10.1007/s11063-020-10404-7> (date of access: 11.12.2025).

126. PK-GCN: prior knowledge assisted image classification using graph convolution networks / X. Xiao et al. Ithaca, NY, USA : Cornell University, 2020. 11 p. (Preprint. Cornell University ; arXiv.2009.11892). URL: <https://doi.org/10.48550/arXiv.2009.11892> (date of access: 13.12.2025).

127. SiNC: saliency-injected neural codes for representation and efficient retrieval of medical radiographs / J. Ahmad et al. *PLOS ONE*. 2017. Vol. 12, no. 8. P. e0181707. URL: <https://doi.org/10.1371/journal.pone.0181707> (date of access: 11.12.2025).

128. Hierarchical medical image report adversarial generation with hybrid discriminator / J. Zhang et al. *Artificial Intelligence in Medicine*. 2024. Vol. 151. P. 102846. URL: <https://doi.org/10.1016/j.artmed.2024.102846> (date of access: 13.12.2025).

129. KdTNet: medical image report generation via knowledge-driven transformer / Y. Cao et al. *Database Systems for Advanced Applications*. Cham, 2022. Vol. 13247 : Lecture Notes in Computer Science. P. 117–132. URL: https://doi.org/10.1007/978-3-031-00129-1_8 (date of access: 13.12.2025).

130. Aronson A. R., Lang F.-M. An overview of MetaMap: historical perspective and recent advances. *Journal of the American Medical Informatics Association*. 2010. Vol. 17, no. 3. P. 229–236. URL: <https://doi.org/10.1136/jamia.2009.002733> (date of access: 11.12.2025).

131. The classical language toolkit: an NLP framework for pre-modern languages / K. P. Johnson et al. *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing: System Demonstrations* : Proceedings, Online, 1–6 August 2021. Stroudsburg, PA, USA, 2021. P. 20–29. URL: <https://doi.org/10.18653/v1/2021.acl-demo.3> (date of access: 13.12.2025).

132. UMLS users and uses: a current overview / L. Amos et al. *Journal of the American Medical Informatics Association*. 2020. Vol. 27, no. 10. P. 1606–1611. URL: <https://doi.org/10.1093/jamia/ocaa084> (date of access: 10.12.2025).

133. Carreras J. Celiac disease deep learning image classification using convolutional neural networks. *Journal of Imaging*. 2024. Vol. 10, no. 8. P. 200. URL: <https://doi.org/10.3390/jimaging10080200> (date of access: 13.12.2025).

134. Semantic consistency generative adversarial network for cross-modality domain adaptation in ultrasound thyroid nodule classification / J. Zhao et al. *Applied Intelligence*. 2022. Vol. 52, no. 9. P. 10369–10383. URL: <https://doi.org/10.1007/s10489-021-03025-7> (date of access: 10.12.2025).

135. Three-dimensional visualization of thyroid ultrasound images based on multi-scale features fusion and hierarchical attention / J. Mi et al. *BioMedical Engineering OnLine*. 2024. Vol. 23, no. 1. P. 31. URL: <https://doi.org/10.1186/s12938-024-01215-1> (date of access: 10.12.2025).

136. Deep contextualized word representations / M. Peters et al. *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers)* : Proceedings, New Orleans, LA, USA, 1–6 June 2018. Stroudsburg, PA, USA, 2018. P. 2227–2237. URL: <https://doi.org/10.18653/v1/n18-1202> (date of access: 13.12.2025).

137. Herlihy C., Rudinger R. MedNLI is not immune: natural language inference artifacts in the clinical domain. *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 2: Short Papers)* : Proceedings, Online, 1–6 August 2021. Stroudsburg, PA, USA, 2021. P. 1020–1027. URL: <https://doi.org/10.18653/v1/2021.acl-short.129> (date of access: 13.12.2025).

138. Adaptive weighted multi-teacher distillation for efficient medical imaging segmentation with limited data / E. B. Loussaief et al. *Knowledge-Based Systems*. 2025. Vol. 315. P. 113196. URL: <https://doi.org/10.1016/j.knosys.2025.113196> (date of access: 26.02.2026).

139. Romanov A., Shivade C. Lessons from natural language inference in the clinical domain. *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing* : Proceedings, Brussels, Belgium, 31 October – 4 November 2018. Stroudsburg, PA, USA, 2018. P. 1586–1596. URL: <https://doi.org/10.18653/v1/d18-1187> (date of access: 13.12.2025).

140. Enhanced LSTM for natural language inference / Q. Chen et al. *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)* : Proceedings, Vancouver, Canada, 30 July – 4 August 2017. Stroudsburg, PA, USA, 2017. P. 1657–1668. URL: <https://doi.org/10.18653/v1/p17-1152> (date of access: 13.12.2025).

141. Probing biomedical embeddings from language models / Q. Jin et al. *Proceedings of the 3rd Workshop on Evaluating Vector Space Representations for* : Proceedings, Minneapolis, MN, USA, 6 June 2019. Stroudsburg, PA, USA, 2019. P. 82–89. URL: <https://doi.org/10.18653/v1/w19-2011> (date of access: 13.12.2025).

142. Chaban O. Entee94 / idk-medical-ai / IDK MedicalAI thesis suite. *GitHub.com*. URL: <https://github.com/Entee94/idk-medical-ai> (date of access: 09.12.2025).

ДОДАТОК А. СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

Статті у періодичних виданнях, включених до категорії «А» Переліку наукових фахових видань України, або у закордонних виданнях, проіндексованих у базах даних Web of Science Core Collection та/або Scopus

1. Chaban O., Manziuk E., Radiuk P. Method of adaptive knowledge distillation from multi-teacher to student deep learning models. *Journal of edge computing*. 2025. Vol. 4, no. 2. P. 159–178. URL: <https://doi.org/10.55056/jec.978> (індексована в наукометричній базі Scopus)

Статті у наукових виданнях, включених до Переліку наукових фахових видань України:

2. Чабан О. Р. Метод інтеграції доменних знань на основі графових нейронних мереж для сегментації зображення МРТ серця. *Вісник Хмельницького національного університету. Серія: технічні науки*. 2025. Т. 361, № 1. С. 452–457. URL: <https://doi.org/10.31891/2307-5732-2026-361-62>

3. Чабан О. Р. Метод поєднання контекстних векторних представлень слів із векторним поданням медичного домену. *Вимірювальна та обчислювальна техніка в технологічних процесах*. 2025. Вип. 82, № 2. С. 297–301. URL: <https://doi.org/10.31891/2219-9365-2025-82-42>

4. 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>

Праці, які засвідчують апробацію матеріалів дисертації

5. Intelligent information system for knowledge integration into artificial intelligence models / O. Chaban et al. *Proceedings of the 2nd International Workshop on Advanced Applied Information Technologies: AI & DSS: CEUR-Workshop Proceedings*,

Khmelnitskyi, Ukraine, Zilina, Slovakia, 5 December 2025. Aachen, 2026. P. 145–161.

URL: <https://ceur-ws.org/Vol-4163/paper13.pdf>

6. Knowledge-integrated graph networks for interpretable cardiac MRI analysis / O. Chaban et al. *Proceedings of the 8th international conference on informatics & data-driven medicine* : CEUR-Workshop Proceedings, Lviv, Ukraine, 19–20 November 2025. Aachen, 2025. P. 1–15.

7. 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, Ukraine, 4 April 2025. Aachen, 2025. P. 42–57. URL: <https://ceur-ws.org/Vol-3943/paper09.pdf> (індексована в наукометричній базі Scopus)

8. Чабан О. Р., Манзюк Е. А. Підхід до інтегрування експертних знань в модель U-Net для сегментування зображень МРТ серця. *Нейромережні технології та їх застосування НМТЗ-2024* : матеріали XXII Міжнар. наук. конф., м. Краматорськ-Вінниця-Тернопіль, 11–12 груд. 2024 р. Краматорськ, 2024. С. 145–149. URL: <https://elar.khmnmu.edu.ua/handle/123456789/17766>

9. Чабан О. Р., Манзюк Е. А. Метод дистилляції знань від моделей-вчителів до моделі учня глибокого навчання. *Актуальні проблеми комп'ютерних наук АПКН-2024* : матеріали XVI Всеукр. науково-практ. конф., м. Хмельницький, 15–16 листоп. 2024 р. Хмельницький, 2024. С. 196–199. URL: <https://elar.khmnmu.edu.ua/handle/123456789/17767>

10. Chaban O., Manziuk E. Enhancing medical NLI with integrated domain knowledge and sentiment analysis. *Proceedings of the 12th international conference information control systems & technologies (ICST 2024)* : CEUR-Workshop Proceedings, Odesa, Ukraine, 23–25 September 2024. Aachen, 2024. P. 262–272. URL: <https://ceur-ws.org/Vol-3790/paper23.pdf> (індексована в наукометричній базі Scopus)

Публікації, які додатково відображають наукові результати дисертації

11. Комп'ютерна програма “Інтелектуальна інформаційна система інтеграції знань в моделі штучного інтелекту медичних діагностичних комплексів” :

а. с. 141364 Україна : CR3113021225 / О. Р. Чабан, Е. А. Манзюк, П. М. Радюк. № с202508817 ; заявл. 10.10.2025 ; опубл. 31.01.2026, Бюл. № 97. 20 с. URL: <https://sis.nipo.gov.ua/uk/search/detail/1897624/>

12. 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>

ДОДАТОК Б.

АКТИ ВПРОВАДЖЕННЯ

«ЗАТВЕРДЖУЮ»
Проректор із наукової роботи
Львівського торговельно-економічного університету
Богдан Семак
« 23 » _____ 2025 р.



АКТ

про впровадження в освітній процес Львівського торговельно-економічного університету результатів дисертаційної роботи аспіранта кафедри комп'ютерних наук Хмельницького національного університету Чабана Олександра Романовича «Методи та засоби інтеграції знань у моделі штучного інтелекту медичних діагностичних комплексів»

Ми, комісія в складі: завідувача кафедри комп'ютерних наук, прикладної та вищої математики, к. ф.-м. н., доцента Новосад З. Г. та декана факультету міжнародних економічних відносин та інформаційних технологій, д.е.н., професора Полякової Ю. В. склали цей акт про те, що наукові та практичні результати дисертаційної роботи Чабана О. Р. впроваджені та використовуються в освітньому процесі на кафедрі комп'ютерних наук, прикладної та вищої математики для здобувачів вищої освіти спеціальності 122 «Комп'ютерні науки», зокрема в освітніх компонентах «Інтелектуальний аналіз даних», «Методи та системи штучного інтелекту».

При викладанні цих освітніх компонент викладачами кафедри використовувалися такі матеріали досліджень, отримані Чабаном О. Р. особисто:

1. Розроблені методи інтеграції знань включено до освітнього компонента «Інтелектуальний аналіз даних» як приклади сучасних підходів до створення інтерпретованих та надійних систем штучного інтелекту. На основі запропонованих методів було розроблено лабораторні роботи, у рамках яких здобувачі вищої освіти досліджують вплив інтеграції експертних знань на точність сегментації та класифікації зображень (на прикладі медичних закладів).

2. Удосконалений метод поєднання контекстних векторних представлень слів із векторним поданням домену медичного закладу впроваджено в освітній компоненті «Методи та системи штучного інтелекту», що демонструє здобувачам вищої освіти механізми розробки систем штучного інтелекту, що здатні аналізувати клінічні записи.

3. Розроблену Чабаном О. Р. інтелектуальну інформаційну систему «IDK Medical AB» використано як наочний інструмент в лекційних та практичних заняттях. Програма дає змогу демонструвати роботу впроваджених алгоритмів, візуалізувати результати та аналізувати якість діагностики.

Загалом впровадження цих результатів посилило практичну складову освітнього процесу, поглибило розуміння здобувачами вищої освіти сучасних методів штучного інтелекту в практичній діяльності, зокрема, в медичних закладах та підвищило якість підготовки майбутніх фахівців.

Завідувач комп'ютерних наук, прикладної та вищої математики,
к. ф.-м. н., доцент

 Зоряна НОВОСАД

Декан факультету міжнародних економічних відносин та інформаційних технологій,
д.е.н., професор

 Юлія ПОЛЯКОВА

"ЗАТВЕРДЖУЮ"

Директор комунального підприємства
"Хмельницька інфекційна лікарня"
Хмельницької міської радиОксана ПІДДУБНА
«_____» _____ 2025 р.

АКТ

про впровадження результатів дисертаційної роботи
Чабана Олександра Романовича
«Методи та засоби інтеграції знань у моделі штучного інтелекту медичних
діагностичних комплексів»

Цей акт підтверджує, що результати дисертаційної роботи аспіранта кафедри комп'ютерних наук Хмельницького національного університету Чабана О.Р. були апробовані та впроваджені в роботу Комунального підприємства «Хмельницька інфекційна лікарня» Хмельницької міської ради. На базі комунального підприємства було встановлено прототип інтелектуальної інформаційної системи «IDK Medical AI», який є результатом дисертаційної роботи Чабана О.Р. Прототип використано для аналізу анонімізованих даних ультразвукових досліджень серця, щоб оцінити, як інтелектуальна інформаційна система може допомогти автоматизувати процес діагностування.

У рамках співпраці були використані такі наукові результати, що отримані Чабаном О. Р. особисто, зокрема:

1. Впровадження методу інтеграції знань для сегментації ділянок серця дозволило швидше й точніше розраховувати ключові показники (фракцію викиду, об'єми камер), зменшивши потребу в ручних вимірюваннях.

2. Використано метод класифікації хвороб серця на основі знаннево-орієнтованої графової нейронної мережі, який продемонстрував високу точність у розрізненні різних патологій. Можливість системи пояснювати, на основі яких ознак зроблено висновок, виявилася корисною для лікарів та підвищила довіру до результатів.

3. Використання прототипу інтелектуальної інформаційної системи «IDK Medical AI» прискорило процес аналізу зображень, що дало можливість лікарю більше часу приділяти складним випадкам, використовуючи програму як допоміжний інструмент.

Результати впровадження підтвердили, що розроблені методи та програмне забезпечення мають значний потенціал для оптимізації робочого процесу в діагностиці захворювань серця, підвищення точності та надійності висновків.

Цей акт не є підставою для фінансових розрахунків.

Завідувач відділення



Олена МАРКЕВИЧ

"ЗАТВЕРДЖУЮ"

Директор товариства
з обмеженою відповідальністю

"КЦ НЕЙРОН"

Світлана КІНЧИК

" 22 " 10 2025 р.



АКТ

про впровадження результатів дисертаційної роботи
Чабана Олександра Романовича
«Методи та засоби інтеграції знань у моделі штучного інтелекту медичних
діагностичних комплексів»

Цим актом підтверджується, що результати дисертаційної роботи аспіранта кафедри комп'ютерних наук Хмельницького національного університету Чабана О.Р. були використані в рамках прикладної діяльності ТОВ "КЦ НЕЙРОН" у процесі впровадження прототипів нових програмних застосунків з інтеграцією систем штучного інтелекту.

Під час дослідно-конструкторських робіт були апробовані та інтегровані такі елементи штучного інтелекту, що розроблені Чабаном О.Р. особисто:

1. Метод інтеграції знань для сегментації медичних зображень, що використано для створення програмних модулів, які забезпечують високу точність та анатомічну коректність автоматичного аналізу медичних зображень.

2. Метод класифікації медичних зображень на основі знаннево-орієнтованої графової нейронної мережі, що використано для проектування інтерпретованих моделей класифікації, які враховують клінічні діагностичні правила.

3. Метод адаптивної дистиляції знань від «моделей-вчителів» до «моделі-учня» глибокого навчання, що дало можливість створити обчислювально ефективні та стійкі до варіацій даних моделі штучного інтелекту, які оптимізовані для практичного використання в медичних діагностичних комплексах.

Впровадження зазначених результатів дозволило підприємству оцінити перспективність нових архітектур штучного інтелекту, прискорити створення прототипів інтелектуальних систем аналізу медичних даних та підвищити їхню потенційну точність та надійність.

Цей акт не є підставою для фінансових розрахунків.

Системний менеджер

ДОДАТОК В. ПРОГРАМНИЙ КОД

Програмний код, що використаний у дослідженні, є відкритим для загального доступу у публічному репозиторії на платформі GitHub:

Чабан О. Р. MedicalAI Thesis Suite. GitHub, Inc. URL: <https://github.com/Entee94/idk-medical-ai> (дата звернення: 18.12.2025).

На рис. В.1 наведено знімок екрана репозиторію на платформі GitHub.

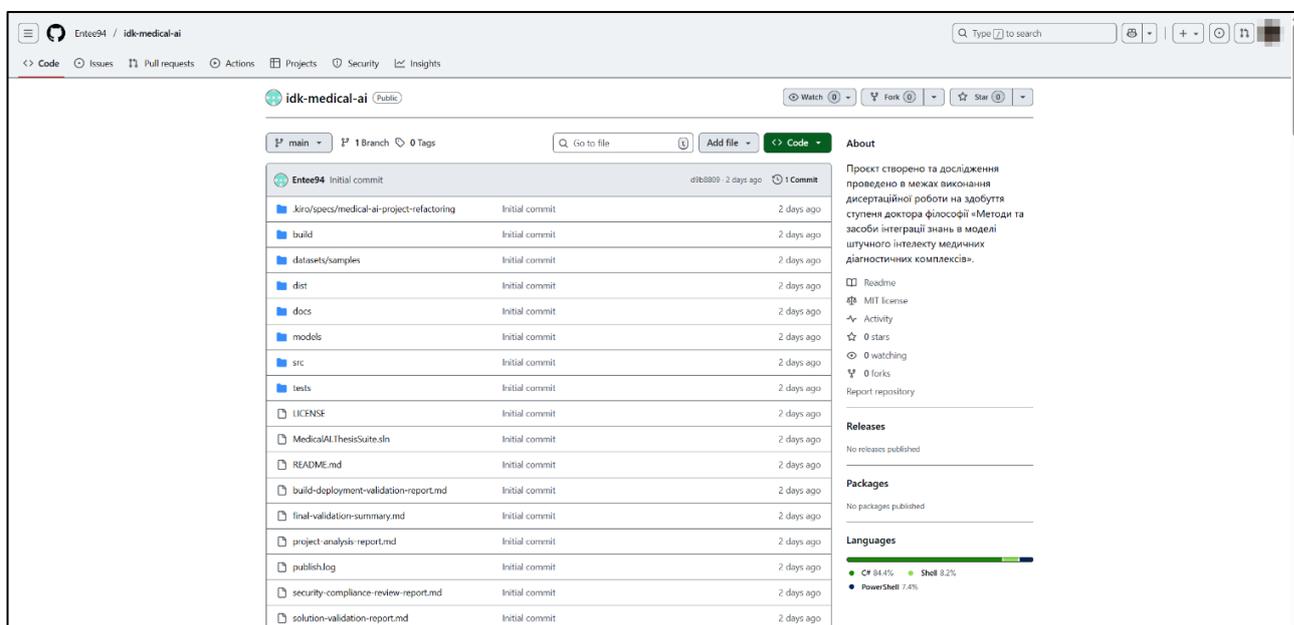


Рисунок В.1 – Головна сторінка репозиторію GitHub з програмним кодом, що використаний у дослідженні для програмної реалізації та експериментального тестування запропонованих у дисертаційній роботі методів

Репозиторій об'єднує програмні компоненти, що реалізують інтелектуальну інформаційну систему «IDK Medical AI», яка описана в розділі 4 дисертації. Головна функція системи – інтеграція експертних знань у моделі глибокого навчання для підвищення точності та надійності процесу медичного діагностування, що забезпечує виконання завдань сегментації, класифікації та аналізу медичних текстів.

Структура репозиторію є такою:

– MedicalAI.Core / Application / Infrastructure – ядро системи, що реалізоване на платформі .NET 8 (C#) та містить доменну модель, логіку застосунку, інтерфейси доступу до даних та механізми інтеграції компонентів;

– MedicalAI.UI – кросплатформовий інтерфейс користувача, реалізований з використанням фреймворку AvaloniaUI та шаблону MVVM, що забезпечує візуалізацію медичних зображень та результатів діагностики;

– MedicalAI.Plugins – модулі, що реалізують запропоновані у дисертації методи мовою програмування Python на основі бібліотек машинного та глибокого навчання (PyTorch, NumPy SciPy, Matplotlib тощо):

а) Distillation.MultiTeacher – модуль адаптивної дистиляції знань за удосконаленням EMTKD;

б) NLP.MedReasoning.UA – модуль встановлення смислових зв'язків у медичних текстах за удосконаленням методом OPNI;

в) Segmentation.SKIFSeg – модуль сегментації зображень МРТ серця за розробленим методом SKIF-Seg;

г) Classification.KIGCN – модуль класифікації та ідентифікації патологій серця за зображенням МРТ за розробленим методом KI-GCN;

– datasets – тека з прикладами медичних даних та скриптами для їхнього попереднього оброблення.

ДОДАТОК Г.

СВІТЛИНИ ІНТЕРФЕЙСУ КОРИСТУВАЧА ПРОГРАМНОГО КОМПЛЕКСУ «IDK MEDICAL AI»

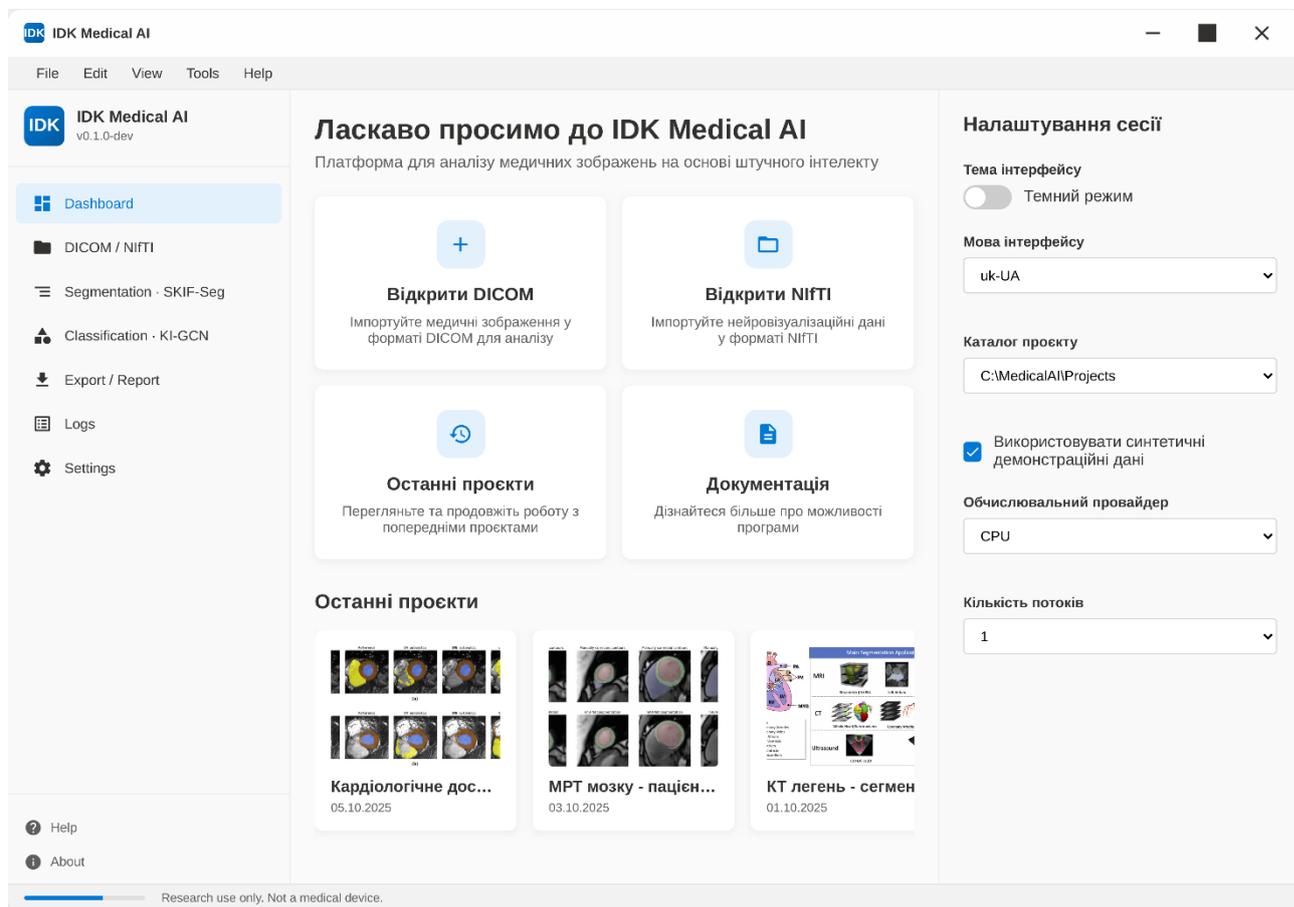


Рисунок Г.1 – Головне меню розробленого програмного комплексу «IDK Medical AI», що забезпечує доступ до модулів завантаження даних, сегментації, класифікації та налаштувань

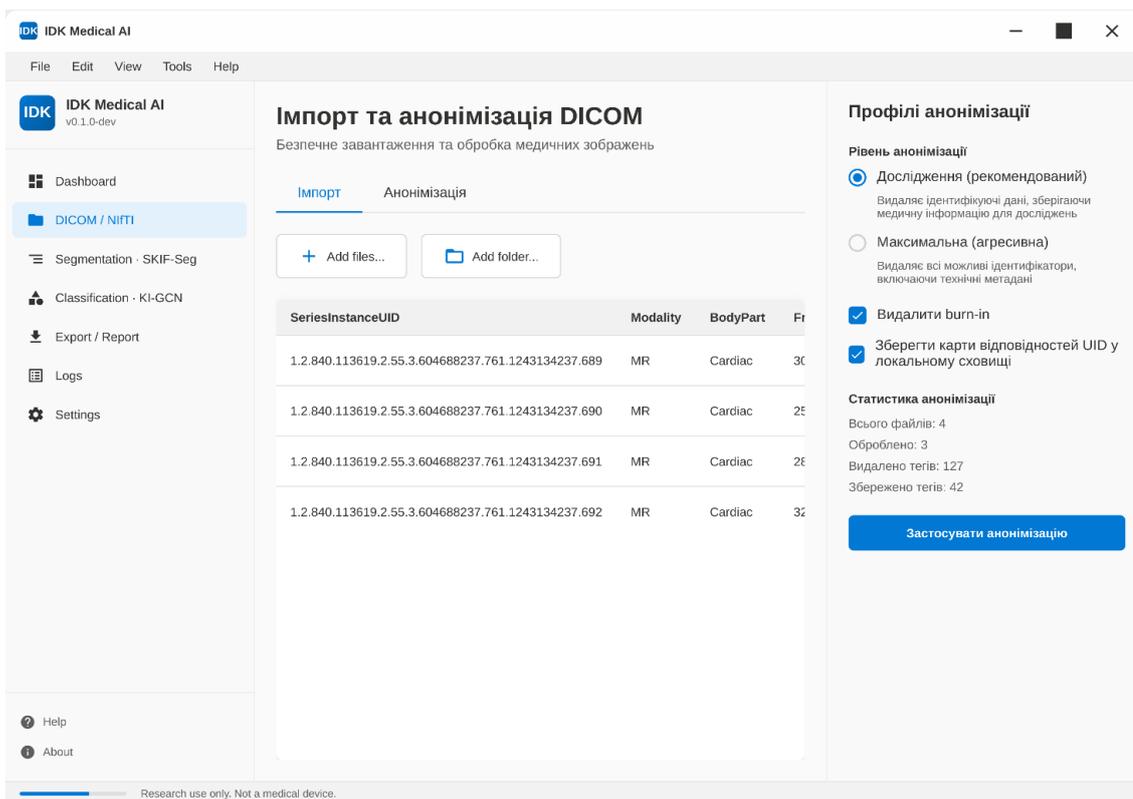


Рисунок Г.2 – Інтерфейс модуля імпорту та анонімізації даних DICOM, що дає змогу застосовувати профілі захисту приватності перед початком аналізу

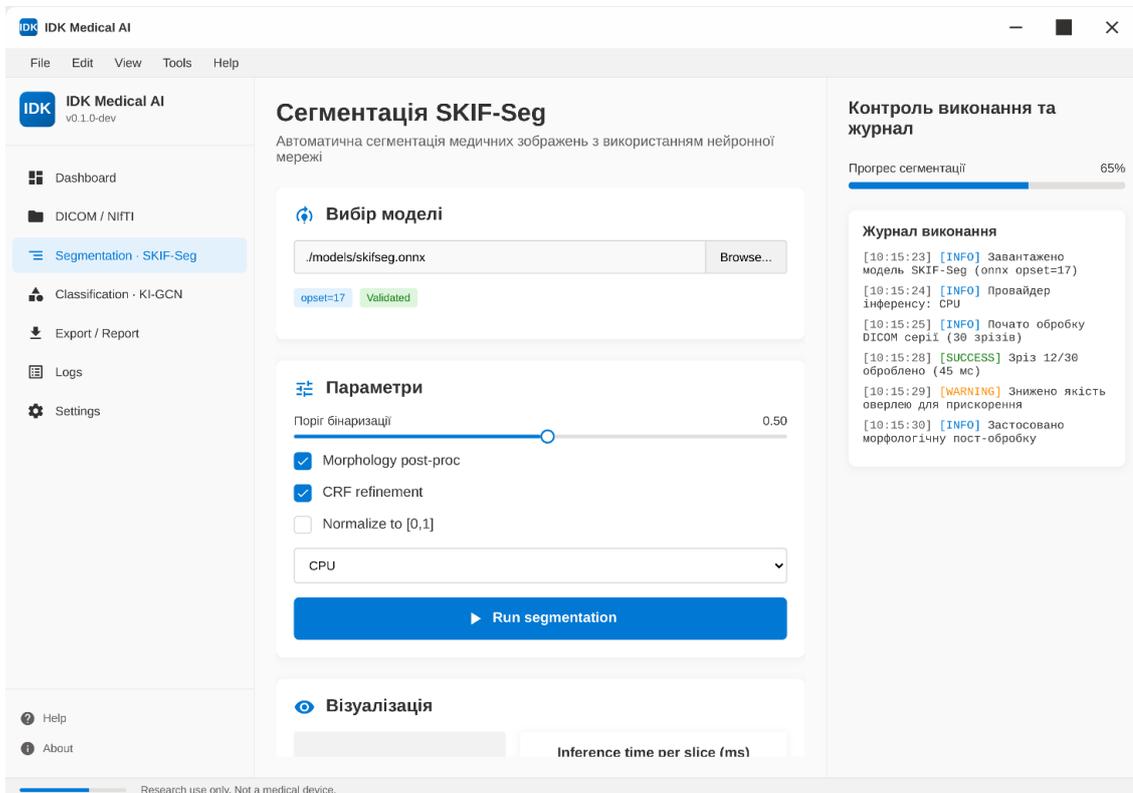


Рисунок Г.3 – Інтерфейс вікна запуску модуля сегментації, що надає можливість вибору моделі, параметрів постоброблення та апаратного прискорювача

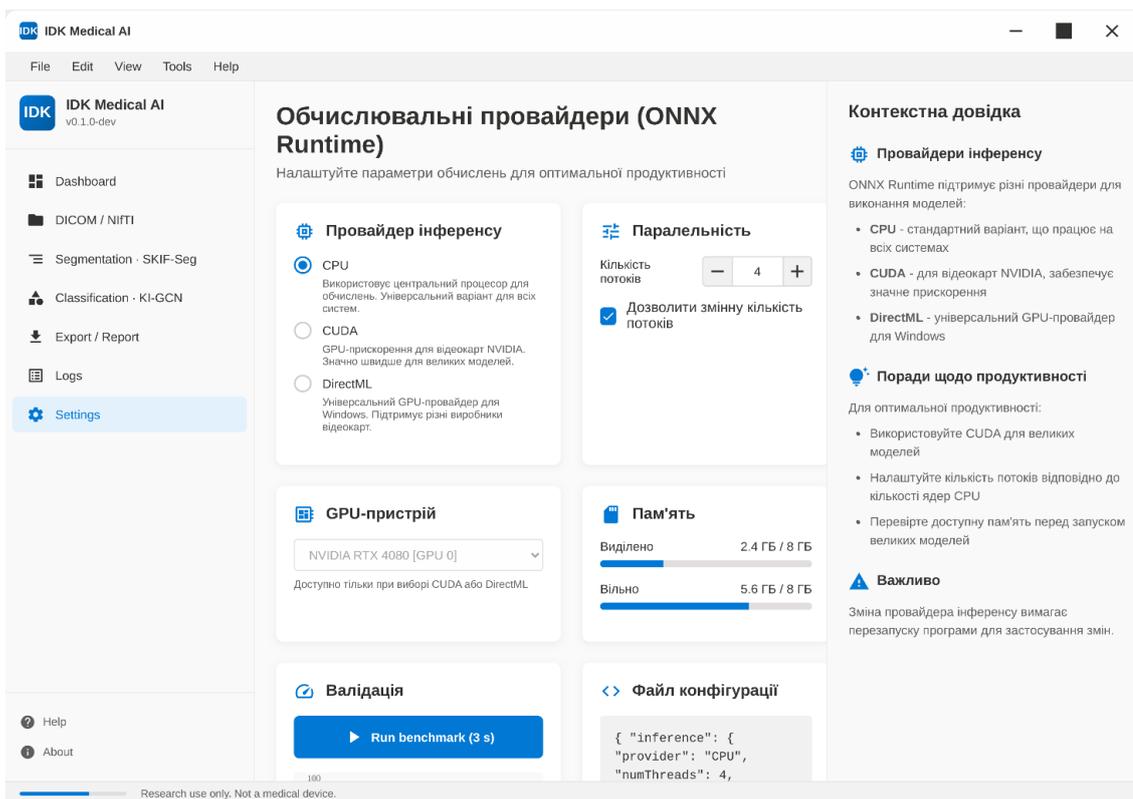


Рисунок Г.4 – Інтерфейс налаштування обчислювальних ресурсів: вибір між CPU, CUDA та DirectML для забезпечення крос-платформеної сумісності

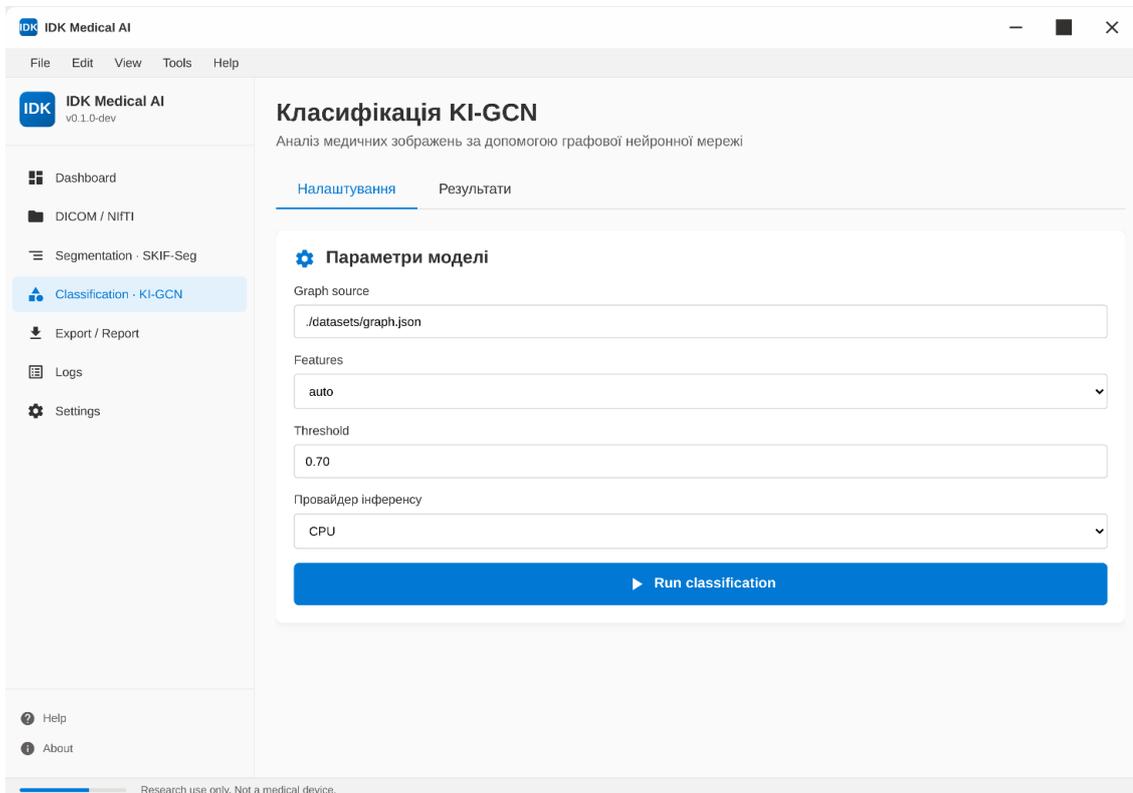


Рисунок Г.5 – Інтерфейс модуля класифікації, що відображає побудований граф пацієнта та ймовірності діагнозів

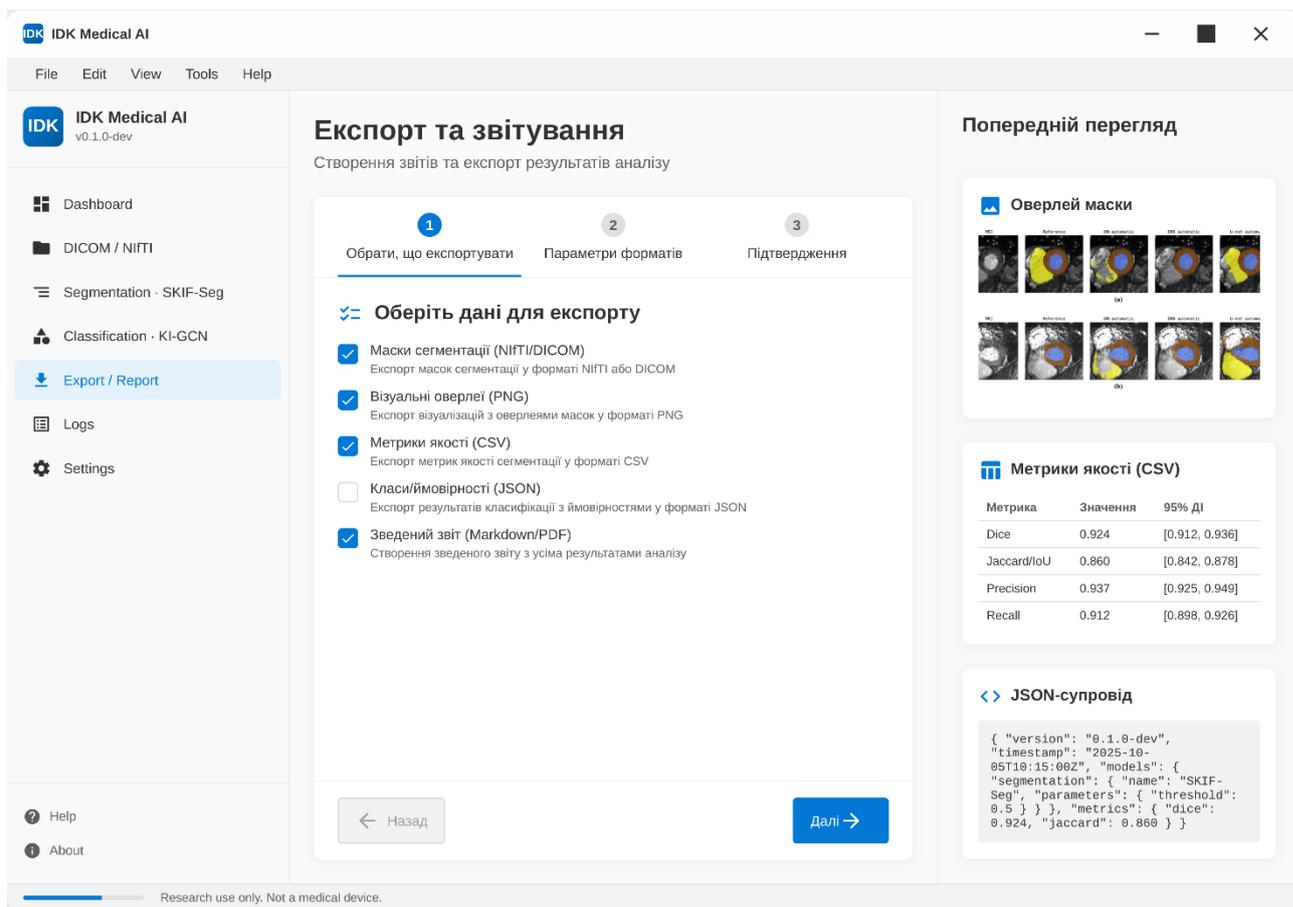


Рисунок Г.6 – Інтерфейс модуля експорту та звітування програмного комплексу «IDK Medical AI», що дає змогу зберігати результати, маніфести експериментів та візуалізації для забезпечення відтворюваності досліджень