ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

Кваліфікаційна наукова праця на правах рукопису

СЛОБОДЗЯН ВІТАЛІЙ ОЛЕКСАНДРОВИЧ

УДК: 004.8

ДИСЕРТАЦІЯ

МЕТОДИ ВИЯВЛЕННЯ ПАТОЛОГІЙ СЕРЦЯ ЗА МРТ-ЗОБРАЖЕННЯМ ЗАСОБАМИ ПОЯСНЮВАЛЬНОГО ШТУЧНОГО ІНТЕЛЕКТУ

122 Комп'ютерні науки

12 Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело.

_____ В.О. Слободзян

Науковий керівник: Бармак Олександр Володимирович, доктор технічних наук, професор

АНОТАЦІЯ

Слободзян Віталій Олександрович. Методи виявлення патологій серця за МРТ-зображенням засобами пояснювального штучного інтелекту. – 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, 2025.

Використання штучного інтелекту в медичній ліагностиці сприяє автоматизації аналізу медичних зображень, підвищуючи ефективність виявлення патологій та зменшуючи вплив людського фактора. Серцево-судинні захворювання є провідною причиною смертності у світі, що робить надійні методи їхньої діагностики критично важливими. Магнітно-резонансна томографія (MPT) вважається золотим стандартом завдяки високій точності, однак складність анатомії серця, варіабельність його форми та артефакти зображень ускладнюють аналіз. Додатково, на об'єктивність діагностики впливають когнітивні упередження лікарів, що може призводити до варіативності інтерпретації результатів. Автоматизовані методи на основі ШІ дозволяють мінімізувати ці проблеми, забезпечуючи стандартизований та більш точний підхід до аналізу кардіологічних МРТ.

Об'єкт дослідження є процес виявлення патологій на МРТ-зображенні засобами глибокого навчання з подальшою інтерпретацією отриманих результатів.

Предмет дослідження є методи та засоби глибокого навчання для виявлення патологій на МРТ-зображенні.

Метою дослідження є підвищення точності сегментації та класифікації МРТзображення серця та отримання можливості інтерпретації отриманих за моделями глибокого навчання рішень.

У дисертаційній роботі вперше запропоновано метод багатоступеневої сегментації області серця на області правого шлуночка, лівого шлуночка та міокарда лівого шлуночка, який відрізняється від існуючих методів використанням багатоступеневого підходу, що включає: попередню локалізацію окремих областей

серця з допомогою засобів глибокого навчання; визначення точних контурів окремо для кожної області серця та використання постобробки отриманих результатів гаусівським згладжуванням для уточнення контурів і зменшення артефактів, що разом дозволило покращити точність сегментації.

У дисертаційній роботі вперше запропоновано метод каскадної класифікації патологій за МРТ-зображеннями. Метод відрізняється від існуючих застосуванням особливої структури каскаду класифікаторів за моделями глибокого навчання та використанням МРТ-зображень з інтегрованими даними про сегментацію областей серця, що дозволило підвищити точність класифікації для таких патологій: дилатаційна кардіоміопатія (DCM), гіпертрофічна кардіоміопатія (HCM), інфаркт міокарда зі зниженою фракцією викиду (MINF), аномальний правий шлуночок (ARV).

У дисертаційній роботі вперше запропоновано метод інтерпретації отриманих за глибоким навчанням рішень, який відрізняється від існуючих використанням даних як класифікації, так і сегментації, а також використанням для інтерпретації ознак, які використовуються у медичній практиці, що дозволило зробити отримані рішення прозорими та зрозумілими.

Практичне значення отриманих результатів полягає в доведенні до реалізації теоретичних результатів дисертаційної роботи та у безпосередньому використанні їх на практиці. Запропоновані методи дозволяють вирішувати низку важливих технічних, моральних та юридичних питань, які виникають під час впровадження штучного інтелекту в медичну практику, сприяючи підвищенню ефективності та безпеки сучасної медичної діагностики.

Реалізований метод багатоступеневої сегментації забезпечує користувачу виділення структур МРТ-зображеннях, можливість точного серцевих на використовуючи поєднання моделей глибокого навчання для локалізації та також постобробку результатів допомогою гаусівського сегментації, а за згладжування для уточнення контурів та зменшення артефактів, що дозволяє отримувати точні результати сегментації.

Реалізований метод каскадної класифікації забезпечує аналіз сегментованих зображень МРТ серця за допомогою каскаду моделей глибокого навчання, що дозволяє підвищити точність класифікації серцевих захворювань. Система надає точні результати, що забезпечує обґрунтовану підтримку прийняття діагностичних рішень.

Реалізований метод інтерпретації рішень моделей глибокого навчання дозволяє користувачу отримати прозорі та зрозумілі результати, пояснюючи їх на основі ознак, що використовуються у медичній практиці. Це робить рішення моделей більш доступними для кінцевих користувачів, забезпечуючи довіру до отриманих результатів та їхню інтеграцію у клінічну практику.

Результати дисертаційної роботи впроваджено (додаток Б): у процесі виробничої діяльності ТОВ «АЙ ТІ ХУТ» для розробки промислового програмного забезпечення; у медичному закладі «Сіліцея Сіті+» для цифрового діагностування патологій серця на МРТ-зображеннях з допомогою засобів комп'ютерної діагностики; при виконанні держбюджетних тем Хмельницького національного університету «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (ДР № 0124U000980); у навчальному процесі для студентів першого та другого освітніх рівнів спеціальності «Комп'ютерні науки».

Ключові слова: штучний інтелект, глибоке навчання, магнітно-резонансна томографія, MPT-зображення, сегментація зображень, каскадна класифікація, інтерпретація рішень, серцево-судинні захворювання, діагностика патологій, автоматизований аналіз, пояснюваний штучний інтелект, нейронні мережі, інформаційні технології в медицині.

ANNOTATION

Slobodzian Vitalii. Methods for Detecting Heart Pathologies in MRI Images Using Explainable Artificial Intelligence. – Manuscript copyright.

Thesis on competition of scientific degree of Doctor of Philosophy by specialty 122 – Computer Science. – Khmelnytskyi National University, Khmelnytskyi, 2025.

The use of artificial intelligence in medical diagnostics facilitates the automation of MRI image analysis, enhancing the efficiency of pathology detection and reducing the impact of human factors. Cardiovascular diseases are the leading cause of mortality worldwide, making reliable diagnostic methods critically important. Magnetic resonance imaging (MRI) is considered the gold standard due to its high accuracy; however, the complexity of heart anatomy, variability in its shape, and image artifacts complicate the analysis. Additionally, cognitive biases among physicians can affect diagnostic objectivity, leading to variability in result interpretation. AI-based automated methods help minimize these issues, ensuring a standardized and more precise approach to cardiac MRI analysis.

The object of the study is the process of detecting pathologies in MRI images using deep learning methods, followed by the interpretation of the obtained results.

The subject of the study is the methods and tools of deep learning for detecting pathologies in MRI images.

The aim of the study is to improve the accuracy of segmentation and classification of cardiac MRI images and to enable the interpretation of decisions obtained from deep learning models.

The dissertation introduces, for the first time, a multi-stage segmentation method for cardiac regions, distinguishing the right ventricle, left ventricle, and left ventricular myocardium. This method differs from existing cardiac segmentation approaches by employing a multi-stage process, which includes the preliminary localization of individual cardiac regions using AI techniques, precise contour detection for each region separately, and post-processing of the results using Gaussian smoothing to refine contours and reduce artifacts. This comprehensive approach has significantly improved segmentation accuracy.

Additionally, the dissertation proposes a novel cascade classification method for detecting heart pathologies in MRI images. Unlike existing methods, this approach utilizes

a unique cascade structure of classifiers based on deep learning models and incorporates MRI images with integrated segmentation data of cardiac regions. This integration has enhanced the accuracy of heart pathology classification, including dilated cardiomyopathy (DCM), hypertrophic cardiomyopathy (HCM), myocardial infarction with reduced ejection fraction (MINF), abnormal right ventricle (ARV), and normal condition (NOR).

Furthermore, the dissertation introduces a method for interpreting deep learningbased decisions. This method differs from existing approaches by leveraging both classification and segmentation data while employing medical-practice-based features for interpretation. As a result, it ensures transparency and comprehensibility of the obtained decisions, making them more interpretable and clinically relevant.

The practical significance of the obtained results lies in the implementation of the theoretical findings of the dissertation and their direct application in practice. The proposed solutions address several critical technical, ethical, and legal challenges associated with the integration of artificial intelligence into medical practice, thereby enhancing the efficiency and safety of modern medical diagnostics.

The developed multi-stage segmentation method enables users to accurately delineate cardiac structures in MRI images by combining deep learning models for localization and segmentation, along with Gaussian smoothing for post-processing. This approach refines contours and reduces artifacts, ensuring high segmentation accuracy.

The implemented cascade classification method facilitates the analysis of segmented cardiac MRI images using a cascade of deep learning models, improving the accuracy of heart disease classification. The system provides reliable results, offering well-founded support for diagnostic decision-making.

The developed interpretation method for deep learning-based decisions allows users to obtain transparent and comprehensible results by incorporating both classification and segmentation data and interpreting them based on features commonly used in medical practice. This enhances the accessibility of model decisions for end users, fostering trust in the obtained results and supporting their integration into clinical workflows.

The results of the dissertation research have been implemented (Appendix B): in the industrial activities of LLC "IT Khut" for the development of industrial software; in the

medical institution "Silicea City+" for digital diagnosis of heart pathologies in MRI images using computer-based diagnostic tools; in the state-funded research projects of Khmelnytskyi National University, including the project "System for Detecting Malware and Cyber Attacks in Corporate Networks Using Decoy Objects and Traps" (State Registration No. 0124U000980); and in the educational process for students of the first and second levels of study in the "Computer Science" specialty.

Keywords: artificial intelligence, deep learning, magnetic resonance imaging, MRI images, image segmentation, cascade classification, decision interpretation, cardiovascular diseases, pathology diagnosis, automated analysis, explainable artificial intelligence, neural networks, information technology in medicine.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у наукових виданнях,

включених до Переліку наукових фахових видань України:

1. Слободзян В. О., Бармак О. В. Метод класифікації МРТ-зображень серця за каскадними моделями глибокого навчання. *Оптико-електронні-інформаційно-енергетичні технології*. 2024. Т. 48, Вип. 2. С. 104–113. (https://doi.org/10.31649/1681-7893-2024-48-2-104-113).

2. Слободзян В. О., Бармак О. В. Метод сегментації МРТ серця на основі локалізації масок. *Вісник Хмельницького національного університету*. 2024. Т. 343, № 6 (1). С. 288–294. (https://doi.org/10.31891/2307-5732-2024-343-6-43).

3. Slobodzian V., Barmak O. Method for interpreting decisions made by deep learning models. *Computer systems and information technologies*. 2024. № 4. C. 150–156. (https://doi.org/10.31891/csit-2024-4-18).

Публікації, які засвідчують апробацію матеріалів дисертації:

4. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis / P. Radiuk et al. *5th International Conference on Informatics and Data-Driven Medicine, IDDM 2022* : Conference Proceedings, Lyon, 18–20 November 2022. 2022. P. 9–20. URL: <u>https://ceur-ws.org/Vol-3302/paper1.pdf</u>. (*iндексована в наукометричній базі Scopus*).

5. Myocardium Segmentation using Two-Step Deep Learning with Smoothed Masks by Gaussian Blur / V. Slobodzian et al. *6th International Conference on Informatics and Data-Driven Medicine, IDDM 2023*: Conference Proceedings, Bratislava, 17–19 November 2022. 2023. P. 77–91. URL: <u>https://ceur-ws.org/Vol-3609/paper7.pdf</u>. *(індексована в наукометричній базі Scopus).*

6. Multi-Stage Segmentation and Cascade Classification Methods for Improving Cardiac MRI Analysis / V. Slobodzian et al. *Information Technology and Implementation* (*IT&I-2024*) : Conference Proceedings, 20–21 November 2024. Kyiv, 2024. URL: <u>https://arxiv.org/pdf/2412.09386</u>.

Свідоцтво про реєстрацію авторського права на твір:

7. А. с. 133517 Україна. Комп'ютерна програма «Класифікація МРТ на наявність патологій з подальшою інтерпретацією результатів» / В. О. Слободзян, О. В. Бармак, П. М. Радюк. 2025.

3MICT

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	13	
ВСТУП	14	
РОЗДІЛ 1. АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ПІДХОДІВ ДО І	ЗИЯВЛЕННЯ	
ПАТОЛОГІЙ СЕРЦЯ ЗА МРТ-ЗОБРАЖЕННЯМ	ЗАСОБАМИ	
ПОЯСНЮВАЛЬНОГО ШТУЧНОГО ІНТЕЛЕКТУ	22	
1.1. Актуальність застосування методів та підходів до виявлення па	тологій серця	
за МРТ-зображенням засобами пояснювального штучного інтелекту	22	
1.2. Огляд сучасних підходів до виявлення патологій серця за МРТ	-зображенням	
засобами пояснювального штучного інтелекту	23	
1.2.1. Сегментація МРТ-зображень серця	24	
1.2.2. Класифікація МРТ-зображень серця	29	
1.2.3. Інтерпретованість рішень, отриманих моделями глибокого навчання	34	
1.3. Сучасні архітектури моделей глибокого навчання для виявлен	ня патологій	
серця за МРТ-зображеннями	37	
1.4. Особливості МРТ-зображень серця та патологій на них	39	
1.5. Ознаки, які вказують на серцеві захворювання	43	
1.6. Оцінка точності моделей глибокого навчання для медичних систе	ем 44	
1.7. Мета та завдання дослідження	46	
1.8. Висновки до розділу 1	47	
РОЗДІЛ 2. МЕТОДИ ВИЯВЛЕННЯ ПАТОЛОГІЙ НА МРТ-ЗОБІ	РАЖЕННІ ЗА	
МОДЕЛЯМИ ГЛИБОКОГО НАВЧАННЯ	49	
2.1. Метод багатоступеневої сегментації МРТ-зображень	51	
2.1.1. Подання інформаційної моделі	51	
2.1.2. Основні кроки методу	63	
2.1.3. Експериментальні моделі та набори даних для валід	ації методу	
багатоступеневої сегментації 67		
2.1.4. Опис стратегії навчання моделей сегментації	70	
2.2. Метод каскадної класифікації МРТ-зображень	73	

		11
2.2.1.	Ідея методу та модель подання	73
2.2.2.	Основні кроки методу	82
2.3.	Висновки до розділу 2	85
РОЗД	ЦІЛ 3. МЕТОД ІНТЕРПРЕТАЦІЇ ОТРИМАНИХ ЗА МОДЕЛ <i>я</i>	ІМИ
ГЛИЕ	БОКОГО НАВЧАННЯ РІШЕНЬ	86
3.1.	Ідея методу	87
3.2.	Модель інтерпретації та візуалізації	89
3.3.	Способи отримання значень ознак	93
3.4.	Основні кроки методу	98
3.5.	Висновки до розділу 3	100
РОЗД	ЦІЛ 4. ЕКСПЕРИМЕНТАЛЬНЕ ПІДТВЕРДЖЕННЯ ВАЛІДНО	OCTI
ЗАПР	РОПОНОВАНИХ МЕТОДІВ	101
4.1.	Опис застосування	101
4.2.	Опис набору даних	105
4.3.	Опис експериментів за методом багатоступеневої сегментації МРТ-зображень	109
4.3.1.	Сегментація оригінальних МРТ-зображень	110
4.3.2.	Сегментація локалізованого МРТ-зображення за оригінальною маскою	112
4.3.3.	Сегментація оригінальних зображень за декомпозованими масками	113
4.3.4.	Сегментація локалізованого МРТ-зображення за декомпозованими масками	115
4.3.5.	Сегментація локалізованого МРТ-зображення за декомпозованими маскам	ИИ З
викор	ристанням постобробки (запропонований підхід)	117
4.3.7.	Валідація експертних масок та отриманих результатів медичним спеціалістом	123
4.3.8.	Аналіз функції втрат навчання та валідації для моделей сегментації	129
4.4.	Опис експериментів за методом каскадної класифікації МРТ-зображень	135
4.5.	Опис експериментів за методом інтерпретації отриманих за модел	ІЯМИ
глибс	окого навчання рішень	141
4.6.	Обмеження запропонованих методів	149
4.7.	Висновки до розділу 4	152
ВИСІ	НОВКИ	154
СПИ	СОК ВИКОРИСТАНИХ ДЖЕРЕЛ	156

ДОДАТОК А. СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА	174
ДОДАТОК Б. АКТИ ВПРОВАДЖЕННЯ	174
ДОДАТОК В. АВТОРСЬКЕ СВІДОЦТВО	179
ДОДАТОК Г. ВИХІДНИЙ КОД	180

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

ΓН	– глибоке навчання.	
ШІ	– штучний інтелект.	
CC3	- серцево-судинні захворювання.	
MPT	 магнітно-резонансна томографія. 	
КТ	 комп'ютерна томографія. 	
УЗД	– ультразвукове дослідження.	
CNN	– convolutional neural network, укр. згорткова нейронна мережа.	
DCM	– dilated cardiomyopathy, укр. дилатаційна кардіоміопатія.	
HCM	– hypertrophic cardiomyopathy, укр. гіпертрофічна кардіоміопатія.	
MINF	– myocardial infarction, necrosis and fibrosis, укр. інфаркт міокарда зі	
зниженою фракцією викиду		
ARV	– abnormal right ventricle, укр. аномальний правий шлуночок.	

ЛШ – лівий шлуночок.

ПШ – правий шлуночок.

МЛШ – міокард лівого шлуночка.

вступ

Актуальність роботи. Використання методів штучного інтелекту (ШІ) у медичній діагностиці дозволяє обробляти складні медичні зображення, виявляти аномалії та пропонувати попередні діагнози, що допомагає лікарям у прийнятті обґрунтованих рішень [1]. Такі технології можуть значно підвищити ефективність діагностичних процесів, зменшуючи залежність від людського фактора та забезпечуючи більш стандартизовані підходи до аналізу даних [2].

Серцево-судинні захворювання (ССЗ) є основною причиною смерті в усьому світі, забираючи приблизно 17,9 мільйона життів щороку [3]. З огляду на такий значний вплив ССЗ на здоров'я населення, важливо мати надійні методи виявлення патологій, що можуть допомогти знизити рівень захворюваності. Магнітнорезонансна томографія (МРТ) серця є критичним інструментом у діагностиці та лікуванні захворювань серця та навколишніх тканин. МРТ серця є основним методом неінвазивного обстеження, який забезпечує високу роздільну здатність та специфічність порівняно з іншими методами візуалізації, такими як комп'ютерна томографія (КТ) та ультразвукове дослідження (УЗД) [4]. МРТ називають «золотим» стандартом завдяки своїй точності, надійності та специфічності [5].

МРТ серця має стандартизовані підходи з метою створення зображень серця для аналізу структури та функцій лівого і правого шлуночків, розширеної характеристики тканин тощо [6]. Однак складна анатомія серця, варіабельність у формі та розмірах органу, а також різні артефакти зображення створюють значні виклики при проведенні МРТ. Артефакти можуть виникати через рухи пацієнта, наявність металевих імплантів або особливості технічного обладнання, що впливає на якість зображень [7]. Це все робить процес аналізу МРТ-зображень надзвичайно трудомістким та вимогливим до ресурсів.

Окрім особливостей МРТ-зображень на точність та об'єктивність аналізу може суттєво впливати людський фактор і упередження. Лікарі можуть піддаватися різним когнітивним упередженням, таким як підтверджувальне упередження або упередженість щодо нещодавніх подій, що може призводити до неправильного діагнозу або невідповідного лікування. Неусвідомлені упередження, зокрема расові або гендерні, також можуть впливати на якість наданої медичної допомоги, призводячи до нерівного доступу до медичних послуг та різних результатів лікування для певних груп пацієнтів. Лікарі можуть по-різному інтерпретувати ті самі клінічні дані, що також ускладнює стандартизацію та підвищення точності діагностики. З іншого боку, сучасна медична наука прагне до зменшення суб'єктивного впливу на лікування [8, 9].

Питанням дослідження інтелектуальних методів аналізу медичних зображень, в тому числі МРТ, присвячено ряд досліджень як українських, так і іноземних вчених: О. Березького [10, 11, 12, 13], І. Ізоніна [14, 15], О. Палагіна [16, 17], О. Авруніна [18, 19], К. Женг (Q. Zheng) [20], Ф. Ісенсее (F. Isensee) [21], А. Мораді (A. Moradi) [22], О. Бернард (O. Bernard) [23, 24, 25, 26], Й. Кублер (J. Kübler) [27, 28], П Раджах (P. Rajiah) [29].

Таким чином, необхідно дотримуватися балансу між об'єктивними показниками і суб'єктивними факторами при ухваленні медичних рішень. Об'єктивні дані та алгоритми ШІ можуть знизити ймовірність упереджень, забезпечуючи більш стандартизований підхід, тоді як суб'єктивна оцінка лікаря дозволяє врахувати унікальні аспекти самопочуття пацієнта, що важко формалізувати. Такий баланс може допомогти оптимізувати процес діагностики та лікування, роблячи його одночасно точним та індивідуалізованим.

Отже, виходячи з наведеного, підвищення точності сегментації та класифікації MPT-зображення серця та отримання можливості інтерпретації отриманих за моделями глибокого навчання рішень є *актуальною науково-прикладною задачею*, одним із шляхів розв'язку якої є розробка та вдосконалення методів глибокого навчання для автоматизованого виявлення патологій на MPT-зображеннях серця з підвищеною точністю сегментації та класифікації, а також створення методів для інтерпретації рішень за отриманими моделями, що дозволять підвищити довіру до таких рішень та сприяти їх клінічному використанню.

Зазначена науково-прикладна задача відповідає предметній області Стандарту вищої освіти України зі спеціальності 122 Комп'ютерні науки для третього

(освітньо-наукового) рівня вищої освіти, зокрема, такому об'єкту вивчення та діяльності, як «процеси обробки інформації у комп'ютерних системах».

Зв'язок роботи з науковими програмами, планами, темами. Дослідження, результати яких викладено в дисертації, виконано під час виконання окремих розділів науково-дослідної роботи за держбюджетною темою Хмельницького національного університету «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (ДР № 0124U000980), в яких автор був виконавцем. У межах проведеної науководослідної роботи за держбюджетною темою автор здійснив розробку методів обробки інформації предметної галузі засобами штучного інтелекту, а також виконав оцінку отриманих результатів за ключовими метриками: Accuracy, Recall, F1-score та ROC-AUC.

Мета і задачі дослідження. *Об'єкт дослідження* – процес виявлення патологій на МРТ-зображенні засобами глибокого навчання з подальшою інтерпретацією отриманих результатів.

Предмет дослідження – методи та засоби глибокого навчання для виявлення патологій на МРТ-зображенні.

Мета дослідження – підвищення точності сегментації та класифікації МРТзображення серця та отримання можливості інтерпретації отриманих за моделями глибокого навчання рішень.

Для досягнення поставленої мети необхідно розв'язати такі задачі:

1. Провести аналіз сучасного стану методів та засобів глибокого навчання, що використовуються для обробки та аналізу медичних зображень, зокрема МРТ серця, та виявлення патологій, а також методів інтерпретації результатів систем штучного інтелекту.

2. Розробити метод багатоступеневої сегментації області серця на МРТзображенні на регіони правого шлуночка, лівого шлуночка та міокарда, який поєднує моделі U-Net і ResNet для локалізації та сегментації серцевих структур, з подальшою постобробкою згладжуванням Гауса для уточнення контурів та зменшення артефактів. 3. Розробити метод каскадної класифікації патологій: дилатаційна кардіоміопатія (DCM), гіпертрофічна кардіоміопатія (HCM), інфаркт міокарда зі зниженою фракцією викиду (MINF), аномальний правий шлуночок (ARV) та нормальний стан (NOR) на MPT-зображенні для більш точного розрізнення захворювань серця, з використанням сегментованих даних MPT-зображень.

4. Розробити метод інтерпретації, отриманих за глибоким навчанням рішень, за ознаками, які використовуються у медичній практиці.

5. Провести експериментальні дослідження спроможності розроблених методів розв'язувати поставлену задачу з потрібною якістю та відповідною інтерпретованістю.

Методи дослідження. При розв'язанні поставленої науково-прикладної задачі використовувались аналіз та синтез, принципи загальної теорії систем та системного аналізу, методи аналізу та моделювання систем, теоретико-множинні підходи, методи концептуального моделювання, методи емпіричного дослідження, моделі глибокого навчання.

Наукова новизна дисертаційного дослідження полягає у одержанні таких наукових результатів:

1. Вперше запропоновано метод багатоступеневої сегментації області серця на області правого і лівого шлуночків та міокарда лівого шлуночка, який відрізняється від існуючих методів використанням багатоступеневого підходу, що включає: попередню локалізацію окремих областей серця з допомогою засобів глибокого навчання; визначення точних контурів окремо для кожної області серця та використання постобробки отриманих результатів згладжуванням Гауса для уточнення контурів і зменшення артефактів, що разом дозволило покращити точність сегментації.

2. Вперше запропоновано метод каскадної класифікації патологій за МРТзображеннями, який відрізняється від існуючих застосуванням особливої структури каскаду класифікаторів за моделями глибокого навчання та використанням МРТзображень з інтегрованими даними про сегментацію областей серця, що дозволило підвищити точність класифікації для таких патологій: дилатаційна кардіоміопатія (DCM), гіпертрофічна кардіоміопатія (HCM), інфаркт міокарда зі зниженою фракцією викиду (MINF), аномальний правий шлуночок (ARV).

3. Вперше запропоновано метод інтерпретації, отриманих за глибоким навчанням рішень, який відрізняється від існуючих використанням даних як класифікації, так і сегментації, а також використанням для інтерпретації ознак, які використовуються у медичній практиці, що дозволило зробити отриманні рішення прозорими та зрозумілими.

Практичне значення отриманих результатів. Практичне значення отриманих результатів полягає в доведенні до реалізації теоретичних результатів дисертаційної роботи та у безпосередньому використанні їх на практиці. Запропоновані рішення дозволяють вирішувати низку важливих технічних, моральних та юридичних питань, які виникають під час впровадження штучного інтелекту в медичну практику, сприяючи підвищенню точності та безпеки сучасної медичної діагностики.

Реалізований метод багатоступеневої сегментації забезпечує користувачу можливість точного виділення серцевих структур на МРТ-зображеннях, використовуючи поєднання моделей глибокого навчання для локалізації і сегментації, а також постобробку результатів за допомогою згладжування Гауса для уточнення контурів та зменшення артефактів, що дозволяє отримувати точні результати сегментації.

Реалізований метод каскадної класифікації забезпечує аналіз сегментованих зображень МРТ серця за допомогою каскаду моделей глибокого навчання, що дозволяє підвищити точність класифікації серцевих захворювань. Система надає точні результати, що забезпечує обґрунтовану підтримку прийняття діагностичних рішень.

Реалізований метод інтерпретації рішень моделей глибокого навчання дозволяє користувачу отримати прозорі та зрозумілі результати, пояснюючи їх на основі ознак, що використовуються у медичній практиці. Це робить рішення моделей більш доступними для кінцевих користувачів, забезпечуючи довіру до отриманих результатів і їхню інтеграцію у клінічну практику. Результати дисертаційної роботи впроваджено (додаток Б): у процесі виробничої діяльності ТОВ «АЙ ТІ ХУТ» – для розробки промислового програмного забезпечення; у медичному закладі «Сіліцея Сіті+» – для цифрового діагностування патологій серця на МРТ-зображеннях з допомогою засобів комп'ютерної діагностики; при виконанні держбюджетних тем Хмельницького національного університету «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (ДР № 0124U000980); у навчальному процесі для студентів першого та другого освітніх рівнів спеціальності «Комп'ютерні науки».

Особистий внесок здобувача та внесок інших співавторів у спільних публікаціях. Усі наукові результати дисертаційного дослідження отримані автором особисто. Список опублікованих праць за темою дисертації наведено у списку використаних джерел [30-36]. У спільних публікаціях автору належать такі результати: метод багатоступеневої сегментації МРТ-зображень серця на основі локалізації масок [30, 31, 34]; метод каскадної класифікації МРТ-зображень серця за моделями глибокого навчання [30, 35]; метод інтерпретації прийнятих рішень класифікації серцевих захворювань за МРТ-зображеннями [32]; огляд підходів до інтеграції знань в МРТ-зображення для підвищення інтерпретованості та розробка модуля для доведення концепції [33]; огляд існуючих методів та архітектур для обробки та аналізу МРТ-зображень; розробка модулів та компонентів комп'ютерної програми для проведення експериментів і впровадження результатів дослідження [36]; [30-32] аналіз існуючих методів та рішень, підготовка чернетки рукопису, розробка модулів і компонентів комп'ютерної програми для проведення експериментів; [34-36] аналіз існуючих методів та рішень, підготовка чернетки рукопису, розробка модулів і компонентів комп'ютерної програми для проведення експериментів.

Особистий внесок інших співавторів у спільних публікаціях: у статті [30] П. Радюк виконував рецензування та коригування рукопису, сумісно з автором проводив огляд відомих методів і рішень та проводив підготовку чернетки рукопису; О. Бармак виконував концептуалізацію дослідження та керував

20

рукопису та обговорення результатів дослідження; О. Ковальчук виконував огляд відомих методів та рішень; у статті [31] О. Бармак виконував концептуалізацію дослідження та керував постановкою експериментів, проводив рецензування та коригування рукопису; у статті [32] О. Бармак виконував концептуалізацію дослідження та керував постановкою експериментів, проводив рецензування і коригування рукопису; у статті [33] П. Радюк виконував рецензування та коригування рукопису, огляд відомих методів і рішень, сумісно з автором проводив підготовку чернетки рукопису; О. Бармак виконував концептуалізацію дослідження та керував постановкою експериментів; Ю. Крак проводив рецензування і коригування рукопису та обговорення результатів дослідження; О. Ковальчук виконував огляд відомих методів та рішень; Е. Манзюк виконував огляд відомих методів та рішень; у статті [34] П. Радюк виконував рецензування і коригування рукопису, огляд відомих методів та рішень, сумісно з автором проводив підготовку чернетки рукопису; О. Бармак виконував концептуалізацію дослідження та керував постановкою експериментів; А. Зінгайло виконувала рецензування та коригування рукопису з медичного погляду, проводила переогляд зразків у наборі даних, що використовувався в досліджені; Ю. Крак виконував рецензування і коригування рукопису та обговорення результатів дослідження; у статті [35] П. Радюк виконував рецензування та коригування рукопису, огляд відомих методів і рішень; О. Бармак виконував концептуалізацію дослідження та керував постановкою експериментів; Ю. Крак проводив рецензування і коригування рукопису та обговорення результатів дослідження; О. Ковальчук виконував огляд відомих методів та рішень; у статті [36] О. Бармак виконував концептуалізацію роботи; П. Радюк виконував рецензування та коригування рукопису.

Апробація матеріалів дисертації. Результати дисертаційних досліджень доповідались на наукових семінарах кафедри комп'ютерних наук. Наукові результати роботи доповідалися також на: 5th International Conference on Informatics & Data-Driven Medicine (м. Ліон (Франція), 2022); 6-th International Conference on Informatics & Data-Driven Medicine (м. Братислава (Словаччина), 2023); Information Technology and Implementation (м. Київ (Україна), 2024).

Публікації. Основні положення і результати дисертації були опубліковані в 7 наукових працях (додаток А), зокрема: 3 статі – у фахових наукових журналах України категорії Б; [30, 31, 32], 3 публікації, які засвідчують апробацію матеріалів дисертації (статті у матеріалах конференцій, що індексуються в наукометричній базі Scopus) [33, 34, 35], 1 свідоцтво про реєстрацію авторського права на твір [36] (додаток В).

Структура та обсяг дисертації. Дисертаційна робота складається з анотації, вступу, 4 розділів, висновків, списку використаних джерел із 147 найменувань на 18 сторінках та 4 додатків. Загальний обсяг дисертації становить 180 сторінок, з них 142 сторінки основного тексту. Дисертація містить 60 рисунків та 14 таблиць.

РОЗДІЛ 1.

АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ПІДХОДІВ ДО ВИЯВЛЕННЯ ПАТОЛОГІЙ СЕРЦЯ ЗА МРТ-ЗОБРАЖЕННЯМ ЗАСОБАМИ ПОЯСНЮВАЛЬНОГО ШТУЧНОГО ІНТЕЛЕКТУ

1.1. Актуальність застосування методів та підходів до виявлення патологій серця за МРТ-зображенням засобами пояснювального штучного інтелекту

Використання методів ШІ у медичній діагностиці дозволяє обробляти складні медичні зображення, виявляти аномалії та пропонувати попередні діагнози, що допомагає лікарям у прийнятті обґрунтованих рішень [1]. Такі технології можуть значно підвищити ефективність діагностичних процесів, зменшуючи залежність від людського фактора та забезпечуючи більш стандартизовані підходи до аналізу даних [2].

ССЗ є основною причиною смерті в усьому світі, забираючи приблизно 17,9 мільйона життів щороку [3]. З огляду на такий значний вплив ССЗ на здоров'я населення, важливо мати надійні методи виявлення патологій, що можуть допомогти знизити рівень захворюваності. МРТ серця є критичним інструментом у діагностиці та лікуванні захворювань серця та навколишніх тканин. МРТ серця дозволяє точно оцінити анатомію, функцію шлуночків, життєздатність міокарда, виявити наявність його запалень або закупорок у кровоносних судинах. Це є основним методом неінвазивного обстеження, який забезпечує високу роздільну здатність та специфічність порівняно з іншими методами візуалізації, такими як КТ та УЗД [4]. МРТ називають «золотим» стандартом завдяки своїй точності, надійності і специфічності [5].

МРТ серця має стандартизовані підходи для створення зображень серця для аналізу структури та функцій лівого і правого шлуночків, розширеної характеристики тканин тощо [6]. Однак складна анатомія серця, варіабельність у формі та розмірах органу, а також різні артефакти зображення створюють значні виклики при проведенні МРТ. Артефакти можуть виникати через рухи пацієнта, наявність металевих імплантів або особливості технічного обладнання, що впливає на якість зображень [7]. Це все робить процес аналізу МРТ-зображень надзвичайно трудомістким і вимогливим до ресурсів.

Окрім особливостей МРТ-зображень на точність та об'єктивність аналізу, може суттєво впливати людський фактор і упередження. Лікарі можуть піддаватися різним когнітивним упередженням, таким як підтверджувальне упередження або упередженість щодо нещодавніх подій, що може призводити до неправильного діагнозу або невідповідного лікування. Неусвідомлені упередження, зокрема расові або гендерні, також можуть впливати на якість наданої медичної допомоги, призводячи до нерівного доступу до медичних послуг та різних результатів лікування для певних груп пацієнтів [8, 9]. Лікарі можуть по-різному інтерпретувати ті самі клінічні дані, що також ускладнює стандартизацію та підвищення точності діагностики. З іншого боку, сучасна медична наука прагне до зменшення суб'єктивного впливу на лікування.

чином Таким необхідно дотримуватися балансу між об'єктивними показниками та суб'єктивними факторами при ухваленні медичних рішень. Об'єктивні дані та алгоритми ШІ можуть знизити ймовірність упереджень, забезпечуючи більш стандартизований підхід, тоді як суб'єктивна оцінка лікаря врахувати унікальні лозволяє аспекти самопочуття пацієнта, шо важко формалізувати. Такий баланс може допомогти оптимізувати процес діагностики та лікування, роблячи його одночасно точним та індивідуалізованим.

1.2. Огляд сучасних підходів до виявлення патологій серця за МРТзображенням засобами пояснювального штучного інтелекту

У підрозділі наведено аналіз сучасних підходів до обробки МРТ-зображень серця, зокрема сегментації і класифікації, із використанням класичних та новітніх підходів з використанням ГН. Також розглядаються сучасні підходи до інтерпретації результатів ГН та ШІ, які забезпечують прозорість результатів, підвищення довіри до систем ШІ і можливість їх клінічного застосування.

1.2.1. Сегментація МРТ-зображень серця

Класичні методи сегментації, такі як edge detection-based segmentation method [37], threshold-based segmentation method [38], region-based image segmentation method [39] мають низьку обчислювальну складність, високу швидкість, проте вони значно відстають у точності та якості результатів сучасних методів, заснованих на глибокому навчанні [40].

Методи глибокого навчання стали популярними завдяки своїй здатності виявляти складні патерни в даних. Згорткові нейронні мережі використовують багатошарові архітектури для виявлення цих патернів, а моделі, такі як U-Net та SegNet, дозволяють отримувати точні сегментації навіть з невеликих наборів даних. Перевагою цих методів є їхня висока точність і здатність перенавчання з використанням нових даних, що дозволяє мати моделі, які змінюються відповідно до даних, однак недоліком є велика потреба в обчислювальних ресурсах і необхідність значної кількості тренувальних даних [41]. Також існує проблема довіри до таких систем, тому все більше уваги приділяється застосуванню підходів, таких як human-in-the-loop та human-centric [42, 33].

Гібридні методи, що поєднують класичні та глибокі підходи, є важливою областю досліджень у сегментації зображень. Наприклад, комбінування CNN для попередньої обробки зображень з активними контурами для точного визначення меж дозволяє використовувати переваги обох методів, але потребує більше обчислювальних ресурсів. Такі методи можуть забезпечити високу точність сегментації завдяки ефективній комбінації алгоритмів. Крім того, комбінація декількох глибоких моделей у сегментації зображень, наприклад, ансамблеве навчання або використання різних архітектур для різних етапів, також покращує результати. Такі методи забезпечують високу точність, але мають високі вимоги до обчислювальних ресурсів і складність налаштування [43].

Існують мультимодальні методи, що використовують інформацію з декількох типів зображень, таких як КТ та МРТ, для покращення сегментації. Це дозволяє отримати більш точні результати за рахунок додаткової інформації, але формування таких наборів даних з різних джерел та їх інтеграція є складним завданням [44].

Останнім часом значної популярності набувають підходи самоконтрольованого та напівсамоконтрольованого навчання (Self-Supervised Learning, Semi-Supervised Learning). Такі підходи здатні ефективно вивчати представлення даних без використання міток або з їх малою кількістю, що робить їх неймовірно корисними для роботи з медичними зображеннями, де формування великих наборів даних є чи не головною проблемою. Декілька провідних методів демонструють високу ефективність у цьому контексті. Методи контрастного навчання, такі як [45, 46, 47], демонструють значні успіхи завдяки своїм підходам до навчання через контрастування подібних і відмінних даних. Дослідження [45, 48] фокусуються на виборі ракурсів для контрастного навчання, оптимізуючи цей процес. Подібні підходи також використовуються у галузі сегментації медичних зображень. Наприклад, запропоновані в роботах [49, 50] методи: пропонується ефективне застосування методів самоконтрольованого навчання для сегментації медичних зображень.

У галузі самонавчання особливо виділяється підхід BYOL [51], який є одним з передових методів самонаглядового навчання. Цей підхід використовує дві нейронні мережі: онлайн- та таргетну мережу. Онлайн-мережа оновлюється градієнтним спуском, тоді як таргетна оновлюється експоненційним згладжуванням параметрів онлайн-мережі. Основна ідея полягає в тому, щоб онлайн-мережа вчилася на виходах таргетної мережі без використання негативних прикладів чи контрастних втрат, що значно спрощує процес навчання. Дослідження показали, що BYOL може досягати продуктивності, порівняної з іншими самонаглядовими методами, навіть без використання негативних прикладів.

У роботі [52] запропоновано напівконтрольований підхід до навчання для сегментації серцевих структур у 4D-зображеннях, що дозволяє покращити результати на обмежених наборах анотованих даних, проте цей метод залежить від

складності попереднього навчання. Дослідження [53] пропонує використання генеративних мереж для збільшення даних з метою автоматизованого кількісного аналізу рубцевої тканини серця, що забезпечує високу точність аналізу, однак потребує значної обчислювальної потужності. У роботі [54] представлено модель на основі Vision Transformer для сегментації магнітно-резонансних зображень, яка ефективно комбінує ознаки для підвищення продуктивності моделі, хоча її складність може бути бар'єром для практичного впровадження.

Робота [55] досліджує узагальнення сегментації зображень на основі єдиного джерела, використовуючи підхід, натхненний каузальністю (концепція, яка стосується причинно-наслідкових зв'язків), що допомагає долати розрив між різними наборами даних, але метод має обмеження у випадках складних структур. У дослідженні [56] 3D глибоке навчання порівнюється з методами сегментації на основі рівнів швидкості для аналізу 4D-потокових зображень; глибоке навчання демонструє вищу точність, але може втрачати фізичні характеристики потоків у складних умовах. У роботі [57] використано багатозадачний U-Net для сегментації шлуночків і міокарда, що забезпечує комплексний аналіз, але вимоги до ресурсів залишаються значними. Натомість у дослідженні [58] запропоновано спрощену версію U-Net для сегментації лівого шлуночка, що демонструє високу швидкість і точність для конкретних задач, хоча її узагальнення на інші структури є обмеженими. Ці дослідження представляють прогресивні рішення для покращення сегментації магнітно-резонансних зображень серця, підкреслюючи баланс між продуктивністю, генералізацією та обчислювальною ефективністю.

Деякі сучасні дослідження у сфері магнітно-резонансної візуалізації серця спрямовані на вдосконалення методів синтезу і сегментації зображень, що є критично важливим для діагностики та лікування серцево-судинних захворювань. У дослідженні [59] розроблено методику синтезу магнітно-резонансних зображень серця на основі умовних генеративних змагальних мереж (Conditional GAN), що використовує інформацію про мітки для створення високоякісних синтетичних зображень. Це дозволяє покращити навчання моделей сегментації, але метод залежить від високої якості початкових даних і чутливий до налаштувань. Робота [60] пропонує симуляційну платформу для створення реалістичних магнітнорезонансних зображень з різними анатомічними і контрастними характеристиками, що забезпечує широкий набір даних для навчання алгоритмів, однак складність точної симуляції для складних випадків може обмежити практичне використання. Дослідження [61] наголошувати на сегментації правого шлуночка за допомогою глибокого навчання та багаторівневих архітектур, що забезпечує високу точність і адаптивність до різних параметрів зображення, проте потребує значних обчислювальних ресурсів і високоякісної анотації. У роботі [62] запропоновано зменшення помилок сегментації через використання пізньої ф'южн-стратегії та генеративних мереж для збільшення даних, що підвищує надійність сегментації, але може бути складним для інтеграції в існуючі клінічні системи.

Дослідження в сегментації МРТ-зображень серця активно розвивають інноваційні підходи для покращення точності та врахування невизначеностей у даних. У дослідженні [63] представлено метод об'єднання сегментації та оцінки невизначеності для структур шлуночків серця за допомогою Bayesian CondenseUNet. Цей підхід дозволяє одночасно отримувати точні сегментовані дані та оцінювати ступінь їхньої достовірності, що є критично важливим для клінічного застосування. Основна перевага методу – високий рівень адаптивності до складних даних, проте його реалізація потребує значних обчислювальних ресурсів.

У роботі [64] запропоновано гібридний підхід на основі глибокого навчання для синтезу карт швидкості міокарда, які використовуються для створення цифрових двійників серця. Хоча головна увага зосереджена на аналізі швидкостей, сегментація структур серця є невід'ємною частиною процесу, забезпечуючи основу для побудови точних моделей. Метод демонструє сильний потенціал у моделюванні, але потребує більшого дослідження впливу на точність сегментації в різних умовах.

Дослідження [65] зосереджене на автоматичній оцінці якості магнітнорезонансних зображень серця, що містять артефакти руху, за допомогою мультизадачного навчання та доповнення даних на основі артефактів у К-просторі. Сегментація тут використовується для оцінки впливу артефактів на точність поділу структур. Цей підхід особливо цінний для забезпечення надійності клінічних даних, хоча його застосування може бути ускладнене у випадках сильних артефактів.

Архітектура U-Net із ResNet як енкодером демонструє високу ефективність у різних біомедичних задачах завдяки здатності залишкових зв'язків витягувати багатошарові ознаки. Використання ResNet як фіксованого енкодера у Context Encoder Network значно підвищує точність 2D-сегментації медичних зображень, забезпечуючи збереження просторової інформації та витягування багаторівневих характеристик, що критично важливо для аналізу структур, як-от кровоносні судини або контури клітин. Однак, високі вимоги до обчислювальних ресурсів створюють перешкоди для широкого впровадження у реальній клінічній практиці [66].

Іншим прикладом є сегментація хірургічних інструментів, де ResNet-50 використовується як базовий енкодер у Multi-Scale Dilated Fusion Network. Ця архітектура дозволяє ефективно обробляти великі зображення, зберігаючи дрібні деталі завдяки багатошаровим з'єднанням і злиттю ознак із різних масштабів. Однак, модель залежить від налаштувань гіперпараметрів і якості вихідних даних, що може впливати на її точність [67]. У задачах сегментації пухлин нирок мульти енкодерна U-Net із ResNet-50 забезпечує високу продуктивність завдяки здатності витягувати складні характеристики навіть із великих зображень. У дослідженні підкреслюється важливість якісного попереднього навчання ResNet для досягнення стабільних результатів, що є критичним для роботи із складними наборами даних [68].

Таким чином, дослідження у сфері сегментації та аналізу зображень демонструють великий прогрес завдяки використанню глибокого навчання, генеративних моделей та адаптивного доповнення даних. Роботи зосереджуються на оптимізації архітектур та покращенні універсальності методів для різних сценаріїв, що забезпечує високу точність і зменшує залежність від обмежених даних. Деякі дослідження акцентують увагу на інноваційних підходах до генерації синтетичних даних та усуненні помилок сегментації, що підвищує стійкість моделей до артефактів. Описані дослідження підкреслюють важливість інтеграції сучасних технологій для вдосконалення аналізу медичних зображень, що має потенціал суттєво покращити діагностику та лікування серцевих захворювань.

Однією з головних проблем є залежність багатьох методів від великих обсягів високоякісних даних, які часто складно отримати через обмежений доступ до якісно розмічених медичних зображень. Багато сучасних методів сегментації, особливо глибокі нейронні мережі, мають високі вимоги до обчислювальних ресурсів. Це включає потребу в потужних графічних процесорах (GPU) для тренування моделей. Ще одним недоліком є недостатня інтерпретованість результатів роботи глибоких моделей, що ускладнює їх інтеграцію в клінічну практику.

1.2.2. Класифікація МРТ-зображень серця

Сучасні підходи до класифікації медичних зображень базуються на широкому використанні як класичних методів машинного навчання, так і методів на основі ШІ. Класичні методи, такі як метод опорних векторів (SVM), рішення дерев та ансамблі (наприклад, random forest), часто застосовуються для класифікації медичних зображень за допомогою вручну сформованих ознак, зокрема текстур і форм об'єктів. Хоча ці методи можуть бути ефективними для більш простих задач, вони поступаються глибинним моделям, особливо при роботі з великими наборами даних.

Згорткові нейронні мережі відіграють ключову роль у класифікації медичних зображень, завдяки здатності автоматично витягувати складні ознаки з вхідних даних. Архітектури ResNet [69] і DenseNet [70] є одними з найпопулярніших для розв'язання задач сегментації і класифікації патологій. Наприклад, модель DenseNet продемонструвала високу ефективність у класифікації зображень пухлин, особливо при використанні невеликих патчів з великих цифрових патологічних зображень [71].

Методи штучного інтелекту відзначаються високою точністю та можливістю адаптації через перенавчання на нових даних, що дозволяє створювати моделі, які змінюються і поліпшуються разом з розвитком наборів даних. Це робить їх особливо корисними у динамічних умовах. Проте такі підходи вимагають значних обчислювальних потужностей та великого обсягу даних для ефективного навчання [41]. Крім того, існує питання довіри до рішень, що приймаються штучним інтелектом.

Метод [72] використовує сегментаційні маски для отримання часових рядів даних, пов'язаних з радіусом і товщиною сегментів міокарда. Він застосовується для побудови карт видимого потоку, що представляють рух міокарда та шлуночкових порожнин. Ці витягнуті ознаки руху, разом з ознаками форми, використовуються в моделі логістичної регресії для класифікації п'яти типів кардіопатологій. Основні переваги цього підходу – пояснюваність і простота. Використовуються лише дев'ять вхідних ознак і всього 14 параметрів, що робить його прозорим і легким для інтерпретації, що є важливим для клінічного застосування. Модель класифікації досягає високої точності: 95 % на тренувальній вибірці та 94 % на тестовій, що можна порівняти з передовими методами.

Підхід, описаний в [21], зосереджується на класифікації захворювань за даними МРТ, використовуючи комбінацію моделей сегментації та класифікації. Метод інтегрує сегментацію серцевих структур (лівий і правий шлуночки та міокард лівого шлуночка) з класифікацією захворювань у повністю автоматизованому процесі. Сегментація досягається за допомогою моделі U-Net, яка призначена для сегментації ключових серцевих структур протягом усього серцевого циклу. Модель витягує як статичні, так і динамічні ознаки із сегментація досягається динамічні ознаки із сегментація досягла коефіцієнта дайса 0.945 (лівий шлуночок), 0.911 (міокард) і 0.923 (правий шлуночок) на тестовому наборі. Модель класифікації досягла точності 94 % на тренувальній вибірці та 92 % – на тестовій. Метод забезпечує високу точність як у сегментації, так і в класифікації, досягаючи передових результатів, однак має труднощі у розрізненні певних патологій, зокрема DCM та MINF.

Підхід до класифікації, описаний у [73], використовує поєднання глибокого навчання та ансамблевих класифікаторів для автоматизації діагностики серцевих

захворювань за даними МРТ. Метод інтегрує сегментацію серцевих структур і повністю класифікацію захворювань y автоматизовану систему. Автори використовують архітектуру повністю згорткової нейронної мережі на основі DenseNets, розроблену для сегментації ключових серцевих структур, таких як лівий і правий шлуночки та міокард. Сегментовані області використовуються для витягання клінічно важливих ознак, таких як об'єми шлуночків, маса міокарда та товщина стінок. Ці ознаки потім використовуються для навчання ансамблю класифікаторів, включаючи машини опорних векторів, багатошарові перцептрони та випадкові ліси, для класифікації п'яти категорій (ARV, HCM, MINF, DCM, NOR). Метод досяг високих значень коефіцієнта Дайса у задачах сегментації, досягаючи 0.96 для лівого шлуночка, 0.95 – для правого шлуночка та 0.89 – для міокарда. Ансамбль класифікаторів додає складності і ризиків перенавчання, особливо з невеликим набором даних. Крім того, модель має труднощі з розрізненням схожих патологій, таких як DCM і MINF, що вимагає залучення експертного класифікатора в таких випадках, що підкреслює обмеження базової моделі.

Використання попередньо натренованих моделей демонструє значний потенціал для підвищення точності діагностики. У дослідженні, присвяченому класифікації раку грудей, гібридна модель B2C3NetF2, яка поєднує оптимізацію на основі алгоритму Satin Bowerbird, витягання характеристик і передачу навчання, досягла точності 94.5 %, значно зменшивши обчислювальну складність, що робить її перспективним інструментом для ранньої діагностики [74]. Інше дослідження зосередилося на покращенні моделі RepVGG для класифікації COVID-19 шляхом використання варіаційних автоенкодерів для заповнення пропущених даних, що дозволило досягти точності 95.4 % та підвищити стійкість до неоднорідності в наборах даних [75]. Для класифікації пухлин мозку було вдосконалено ResNet 50 та Inception V3 з використанням багатокласових наборів даних і оптимізації гіперпараметрів, що забезпечило точність 97.68 % і адаптивність до різних типів зображень [76].

Розробка спеціалізованих нейронних мереж для медичної візуалізації підкреслює їхню ефективність у вирішенні конкретних діагностичних завдань. У гематології дослідження запропонувало модель для автоматизованого розпізнавання кров'яних клітин з використанням ResNet-50 та VGG-19, яка досягла точності 99 %, забезпечуючи надійність і зменшуючи залежність від ручної класифікації [77]. Для діагностики захворювань очей була створена ансамблева модель, яка об'єднує DenseNet-201, ResNet-50 та VGG-16, з метою точного визначення патологій сітківки за допомогою контрастного підсилення та фільтрації зображень, що дозволило досягти високої точності на відкритих наборах даних [78]. У сфері класифікації пухлин мозку LCDEiT — лінійно-комплексна трансформерна модель, оптимізована для малих наборів даних за допомогою стратегії «учитель—учень», показала точність 98.11 % і забезпечила ефективність в умовах обмежених обчислювальних ресурсів [79, 80]. Попри вражаючі результати, ці методи можуть обмежуватися потребою в ретельному налаштуванні під конкретні типи даних, що потребує додаткових зусиль для узагальнення та широкого впровадження в клінічну практику.

Попередня обробка зображень і методи їх аугментації відіграють критично важливу роль у покращенні результатів класифікації медичних зображень, особливо для обмежених наборів даних. Дослідження, присвячене некротичному ентероколіту, демонструє, що геометричні та колірні аугментації, а також спеціально розроблені попередньо оброблені канали, такі як підсилення контрасту та виділення контурів, покращують точність класифікації до 7 %, навіть на невеликих наборах даних [81]. У сфері гістологічних досліджень використання методів перекладу фарбування зображень за допомогою StarGAN-v2 показало здатність ефективно створювати синтетичні зображення з високою структурною точністю. Ці зображення суттєво підвищують точність класифікації ракових тканин, наприклад, поліпшення продуктивності моделей ResNet-50 і VGG-16 на 8 % і 9.3 %, відповідно, завдяки розширенню обсягів навчальних даних [82]. Обидва підходи підкреслюють потенціал аугментації та попередньої обробки для розв'язання проблем недостатності даних і підвищення точності моделей, хоча їх ефективність може залежати від специфіки наборів даних і завдань.

Методи, спрямовані на виявлення захворювань, забезпечують високоточну діагностику завдяки адаптації сучасних нейронних архітектур до специфіки медичних зображень. Використання DenseNet у поєднанні з трансферним навчанням для класифікації гістопатологічних зображень грудної залози демонструє точність до 99.28 %, знижуючи ризик перенавчання завдяки ретельній обробці даних і розподілу тренувально-тестових вибірок [83]. Для діагностики раку шкіри використання моделей EfficientNet у дерматоскопічних зображеннях дозволило досягти точності 96.81 %, ефективно розв'язуючи проблему класового дисбалансу та тонких варіацій між типами уражень [84, 85]. Обидва дослідження демонструють важливість архітектур, оптимізованих для конкретних завдань, з акцентом на точність та ефективність обробки зображень. Ці підходи показують, як сучасні моделі можуть підвищити ефективність діагностики у критичних клінічних сценаріях.

У класифікації метастатичного раку ResNet-50 перевершує моделі VGG-16 і VGG-19, демонструючи високу точність навіть на малих патчах з великих зображень, хоча її обчислювальна складність може бути проблемою в умовах обмежених ресурсів [86]. Для класифікації колоректального раку модель досягла понад 80 % точності завдяки здатності витягувати як високо-, так і низькорівневі ознаки, що робить її ефективною, але потребує потужних апаратних ресурсів [87].

У діагностиці хвороби Альцгеймера ResNet-50 продемонструвала 95 % точності завдяки адаптивному використанню залишкових зв'язків та методів попередньої обробки, але її складність створює виклики для впровадження в реальні клінічні умови з обмеженими ресурсами [88]. У задачах класифікації та сегментації мозкових пухлин модель досягла вражаючих 99.6 % точності, завдяки своїй здатності розпізнавати навіть малопомітні аномалії, перевершуючи інші нейронні мережі, такі як DNN та CNN. Однак вона залишається чутливою до налаштувань та залежить від великих обсягів якісних даних [89].

Таким чином дослідження у сфері класифікації медичних зображень зосереджуються на розробці методів, що забезпечують високу точність діагностики завдяки застосуванню глибокого навчання, специфічних нейронних мереж і покращення попередньої обробки даних. У ряді публікацій ResNet архітектура використовується як основа для створення ефективних моделей класифікації. Тож завдяки її здатності долати проблему зникнення градієнта при глибокому навчанні автори успішно розв'язували проблеми, пов'язані з локалізацією та класифікацією патологій. Покращення попередньої обробки, включаючи аугментацію та підготовку зображень, демонструє потенціал для підвищення точності при роботі з обмеженими наборами даних. Основними викликами залишаються боротьба з класовим дисбалансом, забезпечення узагальнення моделей на різноманітних наборах даних і складність інтерпретації результатів у клінічних умовах.

1.2.3. Інтерпретованість рішень, отриманих моделями глибокого навчання

Важливою проблемою, з якою стикаються дослідники та лікарі, залишається пояснюваність (інтерпретованість) моделей ШІ. Розв'язання цієї проблеми є критично важливим для подолання ефекту «чорної скрині», що знижує довіру до результатів ШІ у клінічній практиці. Сучасні дослідження, такі як [90], підкреслюють роль теплових карт та карт помітності у візуалізації важливих областей зображення, на які фокусується модель. Це сприяє підвищенню довіри лікарів до ШІ та покращує точність діагностики рентгенівських і МРТ-зображень.

Ще одне дослідження [22] аналізує поточні досягнення у застосуванні ШІ для кардіоваскулярної діагностики та вказує на зростання ролі технологій для покращення точності й швидкості аналізу зображень, а також для зменшення людських помилок і випромінювання, що є критичним для МРТ. Це дослідження вказує на важливість застосування моделей, які демонструють конкурентні результати порівняно з кваліфікованими лікарями, і підкреслює, що необхідно більше досліджень для вивчення можливостей ШІ у широкому діапазоні кардіологічних застосувань.

Крім того, у публікації [91] автори навели комплексні настанови для оцінки «довіри» до систем ШІ у медичних зображеннях. Важливим аспектом цих настанов є рекомендації щодо того, як уникнути етичних і клінічних ризиків при розробці та впровадженні ШІ в діагностику кардіологічних захворювань, наголошуючи на необхідності сумісності з клінічною практикою. Автори [92] досліджують метод D-TCAV (Deep Taylor-CAV) для сегментації серцевих зображень, що дозволяє здійснити концептуальне пояснення роботи моделі ШІ через ідентифікацію ключових областей зображень, які впливають на прийняття рішення. У дослідженні також наголошується, що D-TCAV дозволяє ідентифікувати специфічні патологічні особливості, наприклад, нерівномірність стінок або відмінності в розмірах камер, надаючи лікарям більш об'єктивні дані для діагностичного аналізу. Це дозволяє не тільки автоматизувати процес діагностики, але й підвищити прозорість і надійність ШІ в кардіологічних дослідженнях, знижуючи ризик упереджених або випадкових рішень моделі. Це дослідження показує, як такі підходи дозволяють підвищити довіру до застосування методів ШІ у клінічній практиці, зокрема для аналізу сегментації серця з високою точністю.

У роботі [93] описані підходи, які дозволяють візуалізувати області зображень, що найбільше впливають на результати класифікації та сегментації. TorchEsegeta, розроблена авторами платформа для інтерпретації рішень моделей глибокого навчання при аналізі медичних зображень, включає метрики для оцінки чутливості й інфідельності пояснень та адаптує існуючі методи до 3D-аналізу, що було протестовано на задачах сегментації судин мозку з використанням TOF-MRA. Авторами [94] запропоновано багатозадачну модель MT-BI-RADS для класифікації та сегментації пухлин в ультразвукових зображеннях молочної залози. Модель використовує дескриптори BI-RADS для інтерпретації діагностичних рішень, сегментації пухлинних областей та аналізу внеску кожного дескриптора з використанням Shapley Values. Автори відзначають, що модель сприяє підвищенню довіри радіологів до результатів аналізу.

У дослідженні [95] запропоновано підхід до інтерпретації моделей глибокого навчання для аналізу одноканальних ЕЕГ. Використання інтерпретованих фільтрів і статистичного аналізу активацій дозволило встановити зв'язок між ключовими сигналами, такими як сонні спіндли або дельта-активність, та передбаченнями моделей для задач класифікації стадій сну. Авторами [96] розроблено фреймворк NeuroXAI для інтерпретації роботи глибоких нейронних мереж у задачах класифікації та сегментації пухлин мозку. Платформа дозволяє створювати візуалізації уваги на основі декількох сучасних методів інтерпретації та забезпечує прозорість роботи моделей для радіологів. NeuroXAI був застосований до задач аналізу MPT-з акцентом на виявлення і сегментацію пухлин.

роботі [97] застосовано підхід глибокого У навчання аналізу лля електрогістерографічних даних з метою прогнозування передчасних пологів. Запропоновано модель з інтерпретаційною структурою, яка поєднує довгострокову пам'ять і часові згорткові мережі. Автори також запропонували підхід для інтерпретації часового ряду, який дозволяє лікарям отримати необхідну інформацію з даних, незважаючи на їх обмежену кількість. У дослідженні [98] поєднано глибоке навчання з технологіями семантичного вебу для діагностики хвороб касави. Модель досягає точності 90.5 % і генерує зрозумілі інтерпретації для користувачівнефахівців, таких як фермери. Застосування графів знань дозволяє інтегрувати контекстну інформацію та знання домену, значно підвищуючи якість прогнозів.

Робота [99] пропонує метрики для кількісного оцінювання пояснюваності моделей, що застосовуються у моніторингу процесів з прогнозування результатів. Автори вводять поняття симбіозу між інтерпретованістю та достовірністю і порівнюють традиційні моделі з post hoc методами інтерпретації на основі значень Шеплі. У дослідженні [100] проведено оцінку 7-и методів виділення важливих областей (saliency methods) для інтерпретації результатів аналізу рентгенівських знімків грудної клітки. Grad-CAM продемонстрував найкращі результати у локалізації патологій, однак всі методи значно поступаються людському еталону, особливо у випадках з дрібними чи складними за формою патологіями.

Робота [101] представляє новий підхід до параметризації кріо-ЕМ карт за допомогою нейронних мереж. Результати включають точне представлення структурних даних та графові інтерпретації, які забезпечують 99 % покриття амінокислотних залишків для карт атомарної роздільної здатності. У дослідженні [102] запропоновано фреймворк для вибору найбільш інформативних ознак у моделях виявлення депресії. Аналіз трьох реальних наборів даних показав, що ключовими ознаками є паузи у мовленні, частота F0 та рухи очей. Запропонований
підхід дозволяє зменшити кількість використовуваних ознак, підвищуючи точність класифікації.

Таким чином, сучасні дослідження підтверджують, що розробка пояснювальних моделей ШІ та їх візуалізація є критично важливими для інтеграції ШІ у кардіологію, підвищуючи надійність і доступність цієї технології для клінічної діагностики та лікування пацієнтів.

1.3. Сучасні архітектури моделей глибокого навчання для виявлення патологій серця за МРТ-зображеннями

У підрозділі проведено аналіз сучасних архітектур моделей глибокого навчання для виявлення патологій серця за МРТ-зображеннями, а саме – моделей сегментації та класифікації, що підходять для МРТ-зображень. Наведено можливі модифікації, а також переваги і недоліки розглянутих архітектур.

Моделі для сегментації МРТ-зображень

Відповідно до огляду сучасних підходів щодо виявлення патологій серця за МРТ-зображенням засобами пояснювального штучного інтелекту, можна зробити висновок, що для задачі сегментації доцільно більш детально розглянути архітектуру моделей ГН U-Net [103] з використанням ResNet архітектури [104] на етапі енкодера для виділення ознак (рис. 1.1).

U-Net була розроблена спеціально для семантичної сегментації біомедичних зображень і найбільше підходить для вирішення подібних завдань. Заміна класичного енкодера обумовлена тим, що ResNet архітектура добре підходить для задач сегментації завдяки своїм залишковим зв'язкам, які запобігають згасанню градієнтів у глибоких мережах і забезпечують передачу інформації між шарами [106]. Архітектура дозволяє витягувати як високорівневі ознаки (для кращого розуміння загальної картини), так і низькорівневі (для кращої деталізації), що дуже важливо для точного визначення контурів (маски).



Рис. 1.1 – Архітектура U-Net із ResNet енкодером [105]

Архітектура U-Net з використанням ResNet як енкодера показує високу ефективність застосування у різних біомедичних задачах. Для сегментації складних структур U-Net із ResNet забезпечує високу точність завдяки залишковим зв'язкам, які дозволяють витягувати багатошарові ознаки. Існує ряд досліджень, які підтверджують ефективність такої архітектури [107, 108, 109].

Таким чином, комбінація U-Net та ResNet надає високі результати у сегментації зображень завдяки здатності моделі працювати як з високо-, так і з низькорівневими характеристиками. Однак її головними недоліками залишаються висока обчислювальна складність для моделей з великою кількістю шарів та необхідність у якісних вхідних даних.

Моделі для класифікації патологій на МРТ-зображенні

Для задачі класифікації також доцільно розглянути ResNet apxitetypy [104], але не у вигляді окремого блоку як для сегментації, а як окрему apxiteкtypy. Ця аpxiteкtypa першочергово була розроблена для класифікації зображень, тож відзначається високою ефективністю для розв'язання подібних задач.

У класичному вигляді архітектура ResNet може складатися з різкої кількості шарів (18, 34, 50, 100, або 101), які включають в себе згорткові шари, шари нормалізації пакетів (Batch Normalization) та активаційні функції ReLU. Мережа

організована у вигляді послідовності резидуальних блоків (рис. 1.2), кожен з яких має свої унікальні параметри та структуру Ці блоки дозволяють мережі вивчати все більш складні та абстрактні ознаки зображень на різних рівнях глибини.



Рис. 1.2 – Схематичний приклад архітектури ResNet [110]

ResNet архітектура широко використовується для задач класифікації медичних зображень, тож існує ряд досліджень [111, 112, 113, 114], які доводять перспективність застосування такої архітектури для МРТ-зображень.

1.4. Особливості МРТ-зображень серця та патологій на них

Магнітно-резонансна томографія – це сучасний, неінвазивний метод медичної візуалізації, що використовує потужне магнітне поле і радіохвилі для отримання детальних зображень внутрішніх органів і тканин тіла. У контексті кардіології МРТ є одним з найефективніших інструментів для вивчення структури й функцій серця, а також для діагностики захворювань серцево-судинної системи. МРТ працює шляхом впливу магнітного поля на атоми водню, які містяться в тканинах тіла. Ці атоми під впливом магнітного поля виробляють сигнали, що зчитуються апаратом і перетворюються на високоточні тривимірні зображення. Цей метод не використовує іонізуюче випромінювання, що робить його безпечним для пацієнтів. [115, 116].

МРТ серця має свої особливості. За допомогою спеціальних контрастних речовин можна деталізувати тканини серця і навіть побачити зони, які мають недостатнє кровопостачання або пошкодження. Окрім цього МРТ дає можливість створити зображення в будь-якій площині. Приклад МРТ-зображень серця зображено на рис. 1.3 де, *a* – коротка вісь; *б* – вертикальна довга вісь; *в* – горизонтальна довга вісь.



Рис. 1.3 – Схематичне відображення орієнтації основних серцевих площин по відношенню до серця [117]

В контексті саме МРТ серця важливо зазначити можливість отримати візуалізацію серця впродовж всього кардіоциклу, а саме – отримання окремих зображень з кінцевої систоли (момент, коли серце максимально скоротилося і виштовхнуло кров із шлуночків) та з кінцевої діастоли (момент, коли серце максимально наповнене кров'ю), що дуже важливо для діагностики, оскільки між цими двома моментами проходить серцевий цикл і різниця між зображеннями серця в цих фазах допомагає лікарям оцінити, наскільки добре працює серце. На рис. 1.4 наведено приклад МРТ-зображення серця у різних фазах кардіоциклу, а саме a – МРТ-зображення впродовж одного кардіоциклу; δ та e – дістолічна та систолічна фази серця на короткій осі, відповідно; e та d – діастолічна та систолічна фази серця на горизонтальній довгій осі, відповідно [119].



Рис. 1.4 – МРТ-зображення серця у різних фазах кардіоциклу

Також МРТ допомагає оцінити основні частини серця: лівий і правий шлуночки та міокард, оскільки вони добре візуалізуються на МРТ-зображеннях. Приклад наведено на рис. 1.5, де *a* – правий шлуночок; *б* – міокард; *в* – лівий шлуночок.



Рис. 1.5 – Сегментоване МРТ-зображення серця

На МРТ-зображеннях можна виявити різні патології серця, наприклад: інфаркт міокарда, кардіоміопатія, запальні процеси, пухлини проблеми з клапанами [118].

У роботі розглядаються такі патології:

– дилатаційна кардіоміопатія (DCM). Це стан, при якому серцевий м'яз (зазвичай лівий шлуночок) розтягується та стоншується, що приводить до збільшення розмірів серця. Через це серце стає слабшим і не здатне ефективно перекачувати кров. На МРТ-зображеннях DCM проявляється збільшенням порожнин серця та стоншенням стінок, а також зниженням насосної функції (зменшення фракції викиду) [27];

– гіпертрофічна кардіоміопатія (НСМ). Це захворювання, яке характеризується надмірним потовщенням (гіпертрофією) стінок серця, часто без очевидної причини, наприклад, гіпертонії. НСМ може перешкоджати нормальному потоку крові та викликати аритмії. На МРТ можна побачити нерівномірне потовщення стінок, особливо в області міжшлуночкової перегородки, що створює перешкоду кровотоку [120];

– інфаркт міокарда зі зниженою фракцією викиду (MINF). Це запалення серцевого м'яза, зазвичай викликане вірусною інфекцією, імунними або токсичними факторами. Інфаркт міокарда зі зниженою фракцією викиду може спричинити пошкодження тканин, зниження функції серця, а в деяких випадках привести до серцевої недостатності. На МРТ-зображеннях міокардит виглядає як зони аномального накопичення контрасту (через запалення або набряк) у міокарді, часто у зовнішніх шарах серцевого м'яза [121];

– аномальний правий шлуночок (ARV). Це генетичне захворювання, при якому м'язова тканина правого шлуночка замінюється жиром або фіброзною тканиною, що викликає порушення ритму серця. ARV часто є причиною раптової серцевої смерті у молодих людей. МРТ дозволяє виявити аномальні зміни структури правого шлуночка, його збільшення та аномалії руху стінок [122].

Вибір саме цих патологій обґрунтований їхньою високою поширеністю та клінічною значущістю. Зазначені патології є 3 найпоширеніших олними [123, захворювань серця 1241. вони характеризуються різноманітними морфологічними та функціональними змінами серця, які можна виявити за допомогою МРТ. Існують якісні публічно доступні набори даних, такі як [23], які містять анотовані МРТ-зображення для кожної з цих патологій. Обрані чотири

патології охоплюють основні категорії серцевих захворювань (кардіоміопатії, запальні захворювання, аритмогенні стани), але не включають весь спектр патологій, які можна виявити на МРТ. Наприклад, ішемічні захворювання, рестриктивна кардіоміопатія, саркоїдоз або вроджені вади залишаються поза цим переліком. Виключення перелічених вище патологій обумовлено їх меншою поширеністю та відсутністю якісних наборів даних, необхідних для дослідження.

1.5. Ознаки, які вказують на серцеві захворювання

Для інтерпретації рішень, прийнятих за моделями глибокого навчання, потрібно перейти від архітектури нейромереж до ознак, які використовують лікарі для виявлення серцевих захворювань. Виходячи з переліку захворювань, класифікація яких розглядається у цій роботі, можна навести основні групи цих ознак: об'єми шлуночків, викидна фракція, співвідношення об'ємів та маси, товщина та варіабельність стінок міокарда.

Група 1. Об'єми шлуночків. Однією з важливих груп є показники об'ємів серця, які допомагають оцінити функціонування лівого та правого шлуночків. Співвідношення об'єму лівого шлуночка до об'єму правого шлуночка в кінці систоли дозволяє оцінити баланс та взаємодію між двома шлуночками під час скорочення серця. Об'єми лівого шлуночка в кінці систоли та діастоли, відповідно, допомагають оцінити його скорочувальну здатність та максимальний об'єм крові, який може містити шлуночок перед скороченням. Аналогічно, об'єми правого шлуночка в кінці діастоли може свідчити про аритмогенну правошлуночкову кардіоміопатію, тоді як зменшений об'єм лівого шлуночка в кінці систоли може вказувати на гіпертрофічну кардіоміопатію [125, 126].

Група 2. Фракція викиду. Фракція викиду є ще однією важливою групою показників, що визначають ефективність викиду крові лівим та правим шлуночками, відповідно. Ці показники є ключовими для діагностики таких захворювань, як дилатаційна кардіоміопатія, де часто спостерігається знижена викидна фракція.

Викидна фракція лівого шлуночка відображає, скільки крові викидається з лівого шлуночка під час кожного скорочення відносно його розміру під час заповнення. Аналогічно, викидна фракція правого шлуночка показує ефективність перекачування крові правим шлуночком, що є важливим для діагностики таких захворювань, як аритмогенна правошлуночкова кардіоміопатія [126].

Група 3. Співвідношення об'ємів та маси. Ця група включає показники, які відображають співвідношення об'ємів серця та маси міокарда, що в різних фазах серцевого циклу допомагають виявити патологічні зміни в міокарді. Наприклад, збільшення маси міокарда відносно об'єму лівого шлуночка може свідчити про гіпертрофічні зміни, тоді як зменшення може вказувати на певні дилатаційні процеси [126, 20].

Група 4. Товщина та варіабельність стінок міокарда. Властивості, що визначають товщину стінки міокарда, також є важливими для класифікації серцевих захворювань. Виміри товщини міокарда у різних фазах серцевого циклу дозволяють оцінити рівномірність її скорочення та релаксації. Наприклад, збільшена товщина стінки міокарда під час діастоли може вказувати на гіпертрофічну кардіоміопатію, тоді як зменшена товщина може свідчити про дилатаційні процеси. Варіабельність товщини під час скорочення і релаксації допомагає оцінити рівномірність та узгодженість скорочень міокарда. Наприклад, висока варіабельність може свідчити про нерівномірні скорочення міокарда, що є характерним для деяких типів кардіоміопатій, таких як гіпертрофічна кардіоміопатія [125].

1.6. Оцінка точності моделей глибокого навчання для медичних систем

Точність отриманих у дослідженні результатів визначатиметься за такими показниками.

Точність сегментації вимірюється за допомогою коефіцієнта Дайса, який порівнює перекриття між прогнозованою та експертною масками.

Коефіцієнт Дайса є однією з найчастіше використовуваних метрик у медичних дослідженнях, зокрема в аналізі МРТ-зображень. Використання цього коефіцієнта

дозволяє порівнювати результати з іншими дослідженнями, що забезпечує їх відтворюваність і співставність. Популярність використання методу Дайса обґрунтована тим, що він враховує як позитивні результати, так і помилки, надаючи просту й інтуїтивно зрозумілу метрику: наскільки добре сегментована область збігається з ідеальною.

Формула коефіцієнта Дайса виглядає таким чином [125]:

$$Dice = \frac{2 \times |A \cap B|}{|A| + |B|},\tag{1.1}$$

де A – набір пікселів; B – набір пікселів істинної сегментації; |A| – кількість пікселів набору A; |B| – кількість пікселів набору B; $|A \cap B|$ – кількість елементів, що перекриваються для набору A та набору B; значення 0 у формулі (1.1) означає відсутність перекриття, а 1 – ідеальний збіг між масками.

Для визначення точності класифікації розраховують середнє значення, враховуючи точність кожного класифікатора на кожному кроці, і беруть середнє арифметичне всіх точок класифікації, щоб отримати загальну точність моделі. Такий підхід забезпечує справедливе порівняння з іншими методами. Для цих розрахунків використовують такі показники:

$$A_{\text{NOR,ARV}} = \frac{A_{Classifier\ 1} + A_{Classifier\ 2}}{2},\tag{1.2}$$

$$A_{\rm HCM} = \frac{A_{Classifier\ 1} + A_{Classifier\ 3}}{2},\tag{1.3}$$

$$A_{\text{MINF,DCM}} = \frac{A_{\text{Classifier 1}} + A_{\text{Classifier 3}} + A_{\text{Classifier 4}}}{3},$$
(1.4)

$$A_{gen} = \frac{A_{NOR} + A_{ARV} + A_{HCM} + A_{MINF} + A_{DCM}}{5},$$
(1.5)

де A_{Classifier 1-4} – точність кожного класифікатора; A_{NOR,ARV,HCM,MINF,DCM} – точність класифікації кожного окремого класу; A_{gen} – загальна точність методу.

Основні метрики для класифікації розраховують за такими формулами [126]:

$$P = \frac{TP}{TP + FP} \tag{1.6}$$

$$R = \frac{TP}{TP + FN} \tag{1.7}$$

$$F_1 = \frac{2 \cdot P \cdot R}{P + R} \tag{1.8}$$

$$A = \frac{TP + TN}{TP + TN + FP + FN}$$
(1.9)

де *TP* (True Positives) – кількість правильно передбачених позитивних класів; *FP* (False Positives) – кількість неправильно передбачених позитивних класів; *FN* (False Negatives) – кількість неправильно передбачених негативних класів; *TN* (True Negatives) – кількість правильно передбачених негативних класів; *P* (Precision) – точність; *R* (Recall) – чутливість; *F*₁ (F1-score) – гармонійне середнє Precision і Recall; *A* (Accuracy) – точність класифікації.

1.7. Мета та завдання дослідження

Отже, у результаті проведеного аналізу галузей медичного діагностування з використанням методів глибокого навчання встановлено значний прогрес у розвитку методів, що спрямовані на покращення точності діагностики та лікування. Зокрема, запропоновані методи дозволяють знизити суб'єктивний вплив на прийняття медичних рішень, зменшити ймовірність упереджень та забезпечити більш стандартизований підхід до аналізу медичних зображень.

Водночас, сучасні системи стикаються з низкою викликів, таких як залежність від великих обсягів високоякісних даних, висока вимогливість до обчислювальних ресурсів та складність інтерпретації результатів моделей глибокого навчання. Для подолання цих проблем дослідження акцентуються на розробці інноваційних методів попередньої обробки даних, створенні пояснювальних моделей штучного інтелекту для покращення точності сегментації та класифікації. Як наслідок, виникає необхідність у подальшому вдосконаленні алгоритмів, здатних забезпечити індивідуалізований підхід до діагностики, одночасно зберігаючи високу точність та прозорість рішень. Такий підхід спрямований на створення систем штучного інтелекту, які інтегрують передові методи обробки зображень з клінічною практикою, що дозволить значно покращити якість медичної допомоги, забезпечити довіру до технологій та підвищити їх доступність для широкого кола користувачів. Розробка таких систем стане важливим кроком на шляху до вдосконалення медичної діагностики та лікування.

Отже, мета роботи полягає у підвищенні точності сегментації та класифікації МРТ-зображення серця та отриманні можливості інтерпретації, отриманих за моделями глибокого навчання, рішень.

Для досягнення наведеної мети дослідження необхідно виконати такі завдання:

1. Провести аналіз сучасного стану методів та засобів глибокого навчання, що використовуються для обробки та аналізу медичних зображень, зокрема МРТ серця, та виявлення патологій, а також методів інтерпретації результатів систем штучного інтелекту.

2. Розробити метод багатоступеневої сегментації, що поєднує моделі U-Net і ResNet для локалізації та сегментації серцевих структур, з подальшою постобробкою гаусівським згладжуванням для уточнення контурів та зменшення артефактів.

3. Розробити метод каскадної класифікації для більш точного розрізнення захворювань серця з використанням сегментованих даних МРТ.

4. Розробити метод інтерпретації, отриманих за глибоким навчанням, рішень в ознаках, зрозумілих кінцевому користувачеві.

5. Провести експериментальні дослідження спроможності розроблених методів вирішувати поставлену задачу з потрібною якістю і відповідною інтерпретованністю.

1.8. Висновки до розділу 1

У розділі здійснено ґрунтовний аналіз сучасних методів і підходів до виявлення патологій серця за допомогою МРТ-зображень з використанням засобів пояснювального штучного інтелекту. Розглянуто та оцінено ефективність алгоритмів сегментації та класифікації медичних зображень, зокрема методів на основі глибоких нейронних мереж, таких як U-Net, ResNet, DenseNet, а також підходів, що забезпечують інтерпретованість результатів.

Огляд підтвердив, що глибокого методи навчання € надзвичайно перспективними для вирішення задач сегментації та класифікації завдяки їх високій здатності до виявлення складних патернів у даних. Водночас виявлено низку проблем, серед яких виділено високу залежність від якісних анотованих наборів значну обчислювальну складність сучасних моделей і недостатню даних. інтерпретованість їхніх рішень. Крім того, зазначено, що сучасні методи не завжди достатньо адаптовані для інтеграції в клінічну практику через складність налаштування моделей під конкретні типи задач і сценарії.

Проведений аналіз дозволив виявити переваги існуючих методів, такі як висока точність і здатність до автоматизації, а також їхні недоліки, що включають ризики перенавчання, проблеми узагальнення на різні набори даних і недостатню прозорість результатів. Це підкреслило необхідність розробки нових підходів, які б поєднували високу точність аналізу із забезпеченням довіри з боку кінцевих користувачів через зрозумілість рішень.

З огляду на зазначене визначено мету та завдання дослідження, які спрямовані на вдосконалення методів сегментації, класифікації та інтерпретації результатів MPT-зображень серця. Зокрема, передбачено розробку підходів, що поєднують архітектури U-Net та ResNet для покращення точності сегментації, створення методу каскадної класифікації для забезпечення високої ефективності в розрізненні патологій, а також впровадження пояснювальних механізмів, які дозволять лікарям краще розуміти отримані результати.

Таким чином, проведений аналіз обґрунтовує доцільність і актуальність поставленої мети дослідження, що полягає в створенні ефективних методів обробки та аналізу медичних зображень, які забезпечуватимуть високу якість діагностики, інтерпретованість результатів та можливість інтеграції в сучасну клінічну практику.

РОЗДІЛ 2.

МЕТОДИ ВИЯВЛЕННЯ ПАТОЛОГІЙ НА МРТ-ЗОБРАЖЕННІ ЗА МОДЕЛЯМИ ГЛИБОКОГО НАВЧАННЯ

У цьому розділі буде розглянуто методи для сегментації та класифікації МРТзображень, а також будуть описані кроки побудови моделей та описи експериментів для проведення валідації. У дослідженні розглядається задача виявлення таких патологій серця за МРТ-зображенням:

- дилатаційна кардіоміопатія (DCM);
- гіпертрофічна кардіоміопатія (HCM);
- інфаркт міокарда зі зниженою фракцією викиду (MINF);
- аномальний правий шлуночок (ARV).

У дослідженні запропоновано декомпозувати задачу виявлення, наведених вище патологій серця за МРТ-зображенням засобами пояснювального штучного інтелекту на такі завдання та відповідні методи для їх вирішення (рис. 2.1):

- метод багатоступеневої сегментації МРТ-зображень;

метод каскадної класифікації патологій;

– метод інтерпретації, отриманих за глибоким навчанням, рішень.



Рис. 2.1 – Запропонована декомпозиція задачі

Запропонована декомпозиція має такі особливості та міркування:

– використовувати для аналізу МРТ-зображень серця не все зображення, а локалізовані та сегментовані на ньому, необхідні для аналізу області (правого і лівого шлуночків та міокарда). Передбачається, що зазначене дозволить моделі

глибокого навчання побудувати більш якісну модель, яка при побудові не буде відволікатися не непотрібні зони зображення. Виділення цієї функції в окреме завдання дозволить підібрати відповідні моделі глибокого навчання, які призначенні саме для такого перетворення;

– набори даних, які використовуються для навчання класифікаторів у медицині, мають особливість, яка полягає у невеликому обсязі даних. При використанні невеликих наборів даних складно досягнути достатньої узагальненості моделі для багатьох класів одразу. Досить розповсюдженою є ситуація сплутування класів. Для подолання цієї проблеми запропоновано багато підходів, аугментація тощо. Використання каскаду окремих бінарних класифікаторів для агрегованих класів дозволить моделі під час навчання (виявлення прихованих залежностей): збільшити кількість зразків для кожного агрегованого класу та зосередитися на конкретних особливостях двох агрегованих класів, що приведе до збільшення точності класифікації.

Усі три поставлених завдання тісно пов'язані між собою. Помилки сегментації мають значний вплив на точність подальшої класифікації та якість інтерпретації в аналізі медичних зображень. Сегментація відіграє роль першого етапу, який виділяє важливі структури, такі як міокард тощо для аналізу. Якщо цей етап виконується викривлені неточно, класифікація отримує дані. ЩО суттєво ускладнює інтерпретацію результатів. Наприклад, якщо сегментація виділила лише частину області інтересу, важливі деталі, які можуть бути ключовими для діагностики, будуть втрачені. Неправильне визначення меж між областями, наприклад, розмивання контурів, спотворює форму або розмір цільової області. Це особливо критично для задач, де розмір або геометрія області є визначальними для постановки діагнозу. У найгіршому випадку, коли сегментація взагалі не виділяє потрібну структуру, класифікація працює з усім зображенням, що спричиняє плутанину через велику кількість нерелевантних даних. Це підкреслює важливість забезпечення високої точності сегментації як основи для ефективної класифікації.

Далі розглядаються детальні описи кожного методу, що використовується для вирішення декомпозованих завдань, зокрема, ключові етапи та особливості реалізації цих методів. Зазначимо, що методи багатоступеневої сегментації та каскадної класифікації докладно описані в поточному розділі, тоді як метод інтерпретації результатів, отриманих за допомогою глибокого навчання, розглянуто у наступному розділі.

2.1. Метод багатоступеневої сегментації МРТ-зображень

У цьому підрозділі представлено структуру методу, який використовується для сегментації МРТ-зображень серця. Опис методу включає такі основні компоненти:

 модель подання — інформаційна модель для розв'язання задачі багатоступеневої сегментації МРТ-зображення серця на області та маски лівого і правого шлуночків та міокарда;

основні кроки методу: 1) формування моделей глибокого навчання;
2) сегментація МРТ-зображень;

 експериментальні моделі – характеристики моделей, що використовувалися для проведення експериментів;

– стратегія навчання – підхід до навчання моделей та налаштування параметрів.

Таким чином, представлений метод дозволяє автоматизувати процес сегментації МРТ-зображень серця, забезпечуючи їх подальший аналіз і застосування у медичних дослідженнях.

2.1.1. Подання інформаційної моделі

Існує оригінальний набір даних [23] D_1 , який містить пари МРТ-зображення та відповідної йому, створеної експертної маски, яка повторює контури зображення трьох об'єктів інтересу області серця: 1) правого шлуночка; 2) міокарда; 3) лівого шлуночка (рис. 2.2):

$$D_1 = \{d_1, d_2, \dots, d_N\}, d_i = (Img_i, Msk_i), i = 1, 2, \dots, N,$$
(2.1)

де Img_i – МРТ-зображення області серця; Msk_i – маска, яка створена експертом для цього зображення; N – кількість зразків (таких пар) у наборі даних.



Рис. 2.2 – Зразок з набору даних [23] *D*₁, де *a* – МРТ-зображенням серця; *б* – маска: *1* – правий шлуночок; 2 – міокард; *3* – лівий шлуночок

Існуючі рішення використовують набір даних D_1 для навчання однієї моделі ГН, яка відразу буде розпізнавати всі три зазначені області серця. Проте є ряд досліджень [43, 44, 46] (див. розд. 1), у яких зазначено, що використання вузькоспеціалізованих моделей ГН дозволяє отримувати більш точну інформацію.

Виходячи з наведеного, у дослідженні висувається припущення, яке полягає у:

1) попередньому визначенні (локалізації) областей МРТ-зображення серця, які містять лівий і правий шлуночки та міокард (що дозволить більше зосередитися на необхідних об'єктах);

2) використання трьох окремих масок замість однієї.

Наведені припущення дозволять підвищити точність сегментації.

Отже, для реалізації наведених припущень необхідно навчити такі моделі глибокого навчання:

*M*₁ – модель глибокого навчання для локалізації на МРТ-зображенні області лівого шлуночка;

*M*₂ – модель глибокого навчання для локалізації на МРТ-зображенні області правого шлуночка;

– M₃ – модель глибокого навчання для локалізації на МРТ-зображенні області міокарда;

 – M₄ – модель глибокого навчання для визначення контурів (маски) лівого шлуночка;

– M₅ – модель глибокого навчання для визначення контурів (маски) правого шлуночка;

– *М*₆ – модель глибокого навчання для визначення контурів (маски) міокарда.

Виходячи із специфіки поставлених завдань, пропонується використовувати певні архітектури моделей глибокого навчання.

Для моделей M₁, M₂, M₃, які призначені для локалізації певних областей на МРТ-зображенні, запропоновано використати архітектуру U-Net [103] 3 використанням ResNet [104] на етапі енкодера для виділення ознак (backbone, feature extractor). Як було зазначено раніше, під час аналізу сучасних архітектур моделей глибокого навчання, одним з недоліків подібних архітектур є значне збільшення обчислювальної складності разом із збільшенням шарів нейромережі. Тому є потреба в дотриманні балансу між збільшенням кількості шарів в архітектурі, можливості нейромережі ефективно навчатися та В наявності обмежень обчислювальних ресурсів. Отже, для моделей локалізації пропонується використати модифікацію ResNet архітектури ResNet-50, де 50 означає загальну кількість шарів у мережі. Такий вибір обумовлений тим, що для зображень з великою роздільною здатністю краще використовувати архітектуру яка має більшу кількість шарів та здатна витягувати більш складні і багаторівневі ознаки, що важливо для обробки зображень з великою кількістю деталей.

Враховуючи зазначене вище, для завдання локалізації пропонується використати архітектуру, зображену на рис. 2.3.



Рис. 2.3 – Запропонована архітектура моделі глибокого навчання U-Net з використанням декодера ResNet-50.

Для моделей M_4, M_5, M_6 , які призначені для визначення контурів (маски) певних областей на МРТ-зображенні, запропоновано використати такий самий підхід, як і для моделей локалізації, проте з використанням іншої модифікації ResNet apxiteктури – ResNet-34. Ця модифікація має лише 34 шари у мережі, отже є більш простою та менш ресурсомісткою моделлю, що робить її кращим вибором для зображень меншого розміру. У випадку зображень невеликого розміру така глибина, як у ResNet-50, може бути зайвою, оскільки менші вхідні дані вже обмежені у своїй складності та деталізації.

Отже, для завдання визначення точних контурів пропонується використати архітектуру, зображену на рис. 2.4.



Рис. 2.4 – Запропонована архітектура моделі глибокого навчання U-Net з використанням декодера ResNet-34.

Приклад очікуваного результату локалізації за моделлю M_1 для лівого шлуночка зображено на рис. 2.5, де *а* – МРТ-зображення на якому жовта маска – лівий шлуночок; жовта рамка – область лівого шлуночка; червона рамка – область локалізації; *б* – локалізоване зображення області лівого шлуночка.



Рис. 2.5 – Очікуваний результат локазізації за моделями

Для навчання моделей глибокого навчання $(M_1, M_2, M_3, M_4, M_5, M_6)$ за наведеними архітектурами потрібні відповідні набори даних. У роботі пропонується отримати ці набори даних перетворень над набором даних D_1 .

Набір даних D_2 навчання моделей M_1 , M_2 , M_3 пропонується у такому вигляді:

$$D_{2} = \{d_{1}, d_{2}, \dots, d_{N}\}, d_{i} = (ctImg_{i}, ctMsk_{i}^{1}, ctMsk_{i}^{2}, ctMsk_{i}^{3}),$$

$$i = 1, 2, \dots, N.$$
(2.2)

де $ctImg_i$ – «обрізане» МРТ-зображення області серця; $ctMsk_i^1$ – «обрізана» маска для лівого шлуночка; $ctMsk_i^2$ – «обрізана» маска для правого шлуночка; $ctMsk_i^3$ – «обрізана» маска для міокарда; N – кількість зразків у наборі даних.

Для створення набору даних D_2 за інформацією з набору даних D_1 потрібно привести всі зображення з набору даних D_1 до одного розміру, тобто всі зображення повинні мати однакову роздільну здатність та співвідношення сторін. Це необхідно для забезпечення архітектурної узгодженості моделей глибокого навчання, таких як ResNet, та оптимізації обчислювальних ресурсів і використання пам'яті. Для базових операцій із зображеннями, таких як зміна співвідношення сторін та обрізка, пропонується використати відповідні функції з бібліотек Python Imaging Library (PIL) [127] та NumPy [128].

Отже, зазначені перетворення проводяться таким чином для всіх зображень і масок з набору даних D_1 (функція ResizeImageAndMask(Img, Msk)):

ResizeImageAndMask(Img, Msk) 01 width, height ← get Img size

02 if width > height then 03 diff ← (width - height) / 2 04 else 05 diff ← (height - width) / 2 06 crop_left, crop_upper, crop_right, crop_lower ← calculate by diff 07 Img.crop(crop_left, crop_upper, crop_right, crop_lower) 08 Img.resize(target_size) 09 Msk.crop(crop_left, crop_upper, crop_right, crop_lower) 10 Msk.resize(target_size)

де вхідними даними ϵ Msk – загальна маска; Img – зображення, $crop(crop_{left}, crop_{upper}, crop_{right}, crop_{lower})$ – функція обрізання зображення із

(2.3)

бібліотеки PIL; *resize*(*target*_{size}) – функція зміни розміру зображення із бібліотеки PIL; вихідними даними є обрізана маска та зображення.

Далі необхідно декомпозувати оригінальні маски Msk_i з набору даних D_1 на маски для лівого і правого шлуночків та міокарда (рис. 2.6).



Рис. 2.6 – Декомпозиція маски, де *а* – загальна маска; *б* – три бінарні маски

Зазначену декомпозицію пропонується провести за таким алгоритмом (функція MaskIntoBinaryMasks(Msk)):

MaskIntoBinaryMasks(Msk)01 h, w \leftarrow get width, height from Msk

```
\begin{array}{l} 02 \ ctMsk\_1 \leftarrow zeros(h, w) \\ 03 \ ctMsk\_2 \leftarrow zeros(h, w) \\ 04 \ ctMsk\_3 \leftarrow zeros(h, w) \end{array}
```

 $\begin{array}{l} 05 \text{ ctMsk}_1[i,j] \leftarrow 1 \text{ if } Msk[i,j] = 1 \\ 06 \text{ ctMsk}_2[i,j] \leftarrow 1 \text{ if } Msk[i,j] = 2 \\ 07 \text{ ctMsk}_3[i,j] \leftarrow 1 \text{ if } Msk[i,j] = 3 \end{array}$

де Msk – загальна маска; $ctMsk_1$, $ctMsk_2$, $ctMsk_3$ – бінарні маски для лівого і правого шлуночків та міокарда; zeros(h, w) – функція заповнення нулями.

Для навчання моделей M_4, M_5, M_6 пропонується сформувати окремі набори даних, відповідно, для лівого шлуночка – D_3 ; правого шлуночка – D_4 ; міокарда – D_5 в такому вигляді:

$$D_3 = \{d_1, d_2, \dots, d_N\}, d_i = (lvImg_i, lvMsk_i), i = 1, 2, \dots, N,$$
(2.5)

де *lvImg_i* – МРТ-зображення області серця лівого шлуночка, локалізоване відповідно до маски; *lvMsk_i* – локалізована маска для лівого шлуночка, *N* – кількість зразків у наборі даних.

$$D_4 = \{d_1, d_2, \dots, d_N\}, d_i = (rvImg_i, rvMsk_i), i = 1, 2, \dots, N,$$
(2.6)

де $rvImg_i$ – МРТ-зображення області серця правого шлуночка; локалізоване відповідно до маски; $rvMsk_i$ – локалізована маска для правого шлуночкач; N – кількість зразків у наборі даних:

$$D_5 = \{d_1, d_2, \dots, d_N\}, d_i = (myoImg_i, myoMsk_i), i = 1, 2, \dots, N,$$
(2.7)

де $myoImg_i$ – MPT-зображення області серця міокарда, локалізоване відповідно до маски; $myoMsk_i$ – локалізована маска для міокарда; N – кількість зразків у наборі даних.

Для створення наборів даних $D_{3,4,5}$ за інформацією з набору даних D_2 потрібно локалізувати та відцентрувати всі зображення та маски з набору даних D_2 (рис. 2.7).



Рис. 2.7 – Приклад МРТ-зображень та масок відповідно до області інтересів для наборів даних D₃ (*a*), D₄ (*б*), D₅ (*в*)

Додатково до зображень додається рамка. Вирізання необхідної частини зображення з областю інтересів по центру пропонується реалізувати за таким перетворенням (функція LocalizeImageAndMask(Image, Mask, expand_coef)):

LocalizeImageAndMask(Image, Mask, expand_coef)

- 01 loc_left, loc_upper, loc_right, loc_lower \leftarrow find non-zero mask values box
- 02 width, height \leftarrow calculate by box values
- $03 \text{ side_length} \leftarrow MAX(width, height)$

04 expansion_size ← side_length × expand_coef / 2 05 loc_left, loc_upper, loc_right, loc_lower ← expand box by expansion_size (2.8)

06 if width > height then
07 loc_upper ← loc_upper - (width - height) / 2
08 loc_lower ← loc_upper + side_length
09 else
10 loc_left ← loc_left - (height - width) / 2
11 loc_right ← loc_left + side_length
12 Image.crop(loc_upper, loc_lower, loc_left, loc_right)
13 Mask.crop(loc_upper, loc_lower, loc_left, loc_right)
де вхідними даними є маска (Mask), зображення (Image) та коефіцієнт для
розширення рамки (expand_coef), crop(loc_upper, loc_lower, loc_left, loc_right))
– функція обрізання зображення з бібліотеки PIL, а вихідними даними є мінімальні

та максимальні індекси рядка та стовпця маски.

Очікуваний результат сегментації зображення, на маски окремо визначених областей міокарда, лівого та правого шлуночків наведено на рис. 2.8.



Рис. 2.8 – Результати сегментації:

а – вхідне зображення; *б* – правий шлуночок; *в* – лівий шлуночок; *г* – міокард

Після отримання результату сегментації, за рахунок того, що застосовувались перетворення над зображеннями при формуванні наборів даних тощо, потрібно уточнити та покращити якість сегментованих зображень. Нагадаємо, що у наборах даних D_2 та D_3 -зображення приводились до одного розміру, але для коректного порівняння з експертною маскою існує потреба повернути його до оригінального розміру для проведення кінцевої валідації методу. Проте зміна розміру звичайним чином може приводити до втрати деталей та появи небажаних артефактів, що, в свою чергу, впливає на кінцеву оцінку результату (рис. 2.9).



Рис. 2.9 – Порівняння маски міокарда: *а* – експертна маска; *б* – маска на виході нейромережі

Для вирішення зазначеної проблеми пропонується використовувати методи згладжування, які забезпечують плавні переходи між пікселями та створюють більш природний вигляд під час зміни розміру зображення. Варто підкреслити, що методи розмиття часто використовують для попереднього розмиття зображення, що може сприяти полегшення подальшого покращення пошуку контурів. Натомість для медичних зображень таких підхід може сприяти втраті важливих деталей. В роботі пропонується застосовувати методи розмиття для обробки вже визначених масок, а не вхідного зображення, з метою їх згладжування для більшої відповідності оригінальному розміру зображення та кращого порівняння з експертною маскою. Серед таких методів часто використовуються Гаусове згладжування, Box Blur, Median Filter, Bilateral Filter, Mean Shift Filter та Laplacian of Gaussian Filter.

Median Filter замінює значення пікселя на медіану сусідніх значень, ефективно видаляє імпульсний шум і зберігає контури (що є недоліком для поставленої задачі). Bilateral Filter є обчислювально затратним, проте дозволяє одночасно згладжувати однорідні області та зберігати межі об'єктів, що робить його ідеальним для задач, де важлива деталізація, проте суперечить поставленому завданню. Вох Blur, завдяки простоті й швидкості, використовується для базових завдань, але часто створює штучний вигляд через рівномірне усереднення. Mean Shift Filter вирізняється можливістю сегментації завдяки кластеризації однорідних областей, але вимагає значних ресурсів і підходить більше для специфічних задач. Гаусове згладжування є універсальним підходом, який забезпечує плавне зменшення шуму з мінімальним спотворенням текстур і є обчислювально ефективним. Недоліком методу Гауса вважають розмиття меж об'єктів, проте у випадку поставленої задачі – це перевага, оскільки це мета завдання. Laplacian of Gaussian Filter поєднує Гаусове згладжування з підсиленням країв, що дозволяє одночасно зменшувати шум і виділяти контури, проте цей метод менш придатний для загального згладжування через його спрямованість на аналіз країв. Тому хоч деякі методи можуть вважатися ефективними для вирішення типових завдань, для описаної проблеми Гаусове згладжування є найкращим рішенням, тому було обрано саме цей метод.

Пропонується використовувати таке перетворення:

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2 + y^2}{2\sigma^2}},$$
(2.9)

де G(x, y) – значення фільтра Гауса в точці (x, y); σ – стандартне відхилення, яке визначає ступінь згладжування; (x, y) – координати пікселя на зображенні.

Вибір значення σ є ключовим для досягнення найкращих результатів при зміні розміру зображення. Занадто малий ступінь згладжування може залишати зайві шуми, тоді як надмірне згладжування може привести до втрати важливих деталей. Обидва випадки негативно впливають на кінцевий результат. Оскільки зображення мають різний розмір, неможливо підібрати єдине значення σ, яке б було ефективним для всіх випадків.

Для автоматичного вибору оптимального значення о для кожного окремого лінійна регресія. розміру зображення використовується Навчання моделі відбувається таким чином: визначається маска, збільшується її розмір до оригінального, використовуючи значення σ від 0 до 1 з кроком 0.1. Розмір зображення та найкраще значення о для нього використовуються для навчання моделі. Ширина зображення виступає вхідним параметром для регресійної моделі, а значення σ – вихідним. Навчена модель здатна передбачити оптимальне значення σ для будь-якого нового розміру зображення. Цей підхід дозволяє автоматизувати вибір параметра σ для згладжування Гауса при зміні розміру зображення, що допомагає зберігати деталі маски та покращує кінцеві результати.

Далі наведено, яким чином пропонується комбінувати знайденні три окремі маски $(ctMsk_i^1, ctMsk_i^2, ctMsk_i^3)$ в одну загальну. Комбінування відбувається за таким алгоритмом (функція *CombineMasks*(ctMsk_1, ctMsk_2, ctMsk_3)):

CombineMasks(ctMsk_1, ctMsk_2, ctMsk_3) 01 height, width ← get width, height from ctMsk_1 02 cmbMsk ← zeros(height, width)

03 cmbMsk[i,j] \leftarrow 1 if ctMsk_1[i,j] = 1 04 cmbMsk[i,j] \leftarrow 2 if ctMsk_2[i,j] = 1 05 cmbMsk[i,j] \leftarrow 3 if ctMsk_3[i,j] = 1

де ctMsk₁, ctMsk₂, ctMsk₃ – бінарні маски для лівого і правого шлуночків та міокарда; cmbMsk – загальна маска; zeros(height, width) – функція заповнення нулями.

Наприкінці потрібно запропонувати, яким чином проходитиме зіставлення (mapping) комбінованої маски до вхідного зображення. Зіставлення відбувається за таким алгоритмом (функція *MapMaskToOriginalSize(cmbMsk, orgImg, ctImg)*):

MapMaskToOriginalSize(cmbMsk, orgImg, ctImg)01 orgH, orgW← get width, height from orgImg02 ctH, ctW← get width, height from ctImg03 mapToOrgMsk← zeros(orgH, orgW)04 mapToCtMsk← zeros(ctH, ctW)

05 mapToCtMsk[loc_left, loc_upper] ← cmbMsk 06 mapToOrgMsk[crop_left, crop_upper] ← mapToCtMsk

де *cmbMsk* – скомбінована маска за (2.10); *orgImg* – оригінальне вхідне зображення; *ctImg* – обрізане зображення; *crop_left*, *crop_upper* – координати верхнього лівого

(2.10)

(2.11)

кутка зображення, за яким виконувалася обрізка зображення за перетвореннями (2.3); loc_{left}, loc_{upper} — координати верхнього лівого кутка зображення, за яким виконувалася локалізація за перетвореннями (2.8); zeros(height, width) — функція заповнення нулями.

2.1.2. Основні кроки методу

Основні кроки методу можна розділити на два етапи: кроки для отримання моделей ГБ та кроки сегментації. Вони будуть детально розглянуті далі.

Кроки для отримання моделей глибокого навчання

Отже, задача отримання моделей глибокого навчання для подальшої сегментації областей інтересу на МРТ-зображенні подається послідовними кроками методу. У цьому підрозділі описуються основні етапи, що включають підготовку даних, вибір архітектури моделі, навчання та валідацію моделей. Послідовність цих кроків представлена на рис. 2.10.



Рис. 2.10 – Основні кроки для отримання моделей глибокого навчання для сегментації областей лівого і правого шлуночків та міокарда на MPT-зображенні

Далі описано кроки створення моделей ГН, які будуть використовуватись для сегментації МРТ-зображення.

Вхідною інформацією є набір даних [23] D₁, який містить пари: МРТзображення та відповідні маски з областями лівого, правого шлуночків та міокарда.

На *кроці 1* відбувається навчання моделей ГН для локалізації областей лівого і правого шлуночків та міокарда. Для цього на *кроці 1.1* готується новий набір даних D_2 , який міститиме замість однієї маски три: для лівого шлуночка, правого шлуночка та міокарда. Для цього:

- крок 1.1.1. Приведення всіх вхідних зображень і масок до єдиного розміру за (2.3);

– крок 1.1.2. Декомпозиція оригінальної маски на маски для лівого і правого шлуночків та міокарда за (2.4).

Таким чином, новий набір даних D₂ міститиме рядки з МРТ-зображенням і трьома масками.

Далі, на *кроці 1.2* проведемо за набором даних *D*₂ навчання трьох моделей ГН для виявлення областей інтересу:

– крок 1.2.1. Навчання моделі ГН (*M*₁) для виявлення області лівого шлуночка;

– крок 1.2.2. Навчання моделі ГН (*M*₂) для виявлення області правого шлуночка;

- крок 1.2.3. Навчання моделі ГН (M₃) для виявлення області міокарда.

Далі на *кроці 2* відбувається навчання моделей ГН для генерації масок за виявленими областями інтересу. На *кроці 2.1* готуються нові набори даних $D_{3,4,5}$ шляхом модифікації набору даних D_2 , а саме застосовується обрізка оригінальних МРТ-зображень та масок відповідно до області інтересів за (2.8).

Далі, на *кроці 2.2* проведемо за наборами даних *D*_{3,4,5} навчання трьох моделей ГН для визначення контурів лівого і правого шлуночків та міокарда:

– крок 2.2.1. Навчання моделі ГН (*M*₄) для визначення контурів лівого шлуночка за набором даних *D*₃;

– крок 2.2.2. Навчання моделі ГН (*M*₅) для визначення контурів правого шлуночка за набором даних *D*₄;

– крок 2.2.3. Навчання моделі ГН (M_6) для визначення контурів міокарда за набором даних D_5 .

Вихідною інформацією є навчені моделі глибокого навчання $M_1, M_2, M_3, M_4, M_5, M_6.$

Кроки для сегментації МРТ-зображень

Задача сегментації довільного МРТ-зображення на області лівого і правого шлуночків та міокарда за допомогою навчених моделей глибокого навчання $(M_1, M_2, M_3, M_4, M_5, M_6))$ подається такими кроками методу (рис. 2.11).



Рис. 2.11 – Основні кроки для сегментації МРТ-зображення

на області лівого шлуночка (ЛШ), правого шлуночка (РШ) та міокарда (МЛШ)

Далі описано кроки сегментації МРТ-зображення на області лівого та правого шлуночків та міокарда.

Вхідною інформацією є МРТ-зображення та моделі ГН $M_1, M_2, M_3, M_4, M_5, M_6$.

На *кроці 1* визначаються області розташування лівого та правого шлуночків та міокарда:

– крок 1.1. За допомогою моделі ГН M₁ визначається область розташування лівого шлуночка;

– крок 1.2. За допомогою моделі ГН M₂ визначається область розташування правого шлуночка;

– крок 1.3. За допомогою моделі ГН M₃ визначається область розташування міокарда.

На *кроці 2* проводиться генерація масок лівого та правого шлуночків та міокарда:

- крок 2.1. За допомогою моделі ГН M₄ визначається маска лівого шлуночка;

– крок 2.2. За допомогою моделі ГН М₅ визначається маска правого шлуночка;

- крок 2.3. За допомогою моделі ГН M₆ визначається маска міокарда.

На кроці 3 проводиться постобробка отриманих масок:

- крок 3.1. Згладжування масок за (2.9);

– крок 3.2. Комбінування 3 окремих масок в одну загальну маску за допомогою (2.10);

– крок 3.3. Зіставлення (mapping) комбінованої маски відповідно до розміру вхідного зображення за допомогою (2.11).

Вихідною інформацією методу є сегментоване довільне МРТ-зображення серця на області лівого і правого шлуночків та міокарда.

Таким чином, процес побудови моделей глибокого навчання включає підготовку даних і навчання моделей для локалізації та генерації масок областей інтересу з використанням модифікованих наборів даних. Проводиться навчання окремих моделей для локалізації визначення контурів лівого і правого шлуночків та міокарда. Загалом було навчено 6 моделей глибокого навчання.

Сегментація МРТ-зображень виконується послідовно: спочатку моделі визначають розташування областей лівого й правого шлуночків та міокарда, після чого генеруються відповідні маски. Завершальним етапом є постобробка масок, яка включає їх згладжування, об'єднання й адаптацію до розміру вхідного зображення. Результатом є сегментоване МРТ-зображення серця.

2.1.3. Експериментальні моделі та набори даних для валідації методу багатоступеневої сегментації

Для перевірки впливу кроків запропонованого методу багатоступеневої сегментації на підсумкову якість сегментації пропонується виконати серію експериментів, у ході яких планується поступово ускладнити процес навчання моделі, додаючи окремі кроки або їх комбінації, з обчисленням показників точності сегментації.

Загальну точність пропонується розраховувати як середнє арифметичне значення точності для всіх структур на кінцевій систолі та кінцевій діастолі за коефіцієнтом Дайса (1.1), що можна описати таким чином:

$$\overline{Dise} = \frac{\sum Dise_s^p}{6}, \qquad p \in \{ES, ED\}, s \in \{RV, LV, MYO\}$$
(2.12)

де \overline{Dise} – загальна точність підходу; $Dise_s^p$ – точність окремого сегмента за коефіцієнтом Дайса (1.1) для лівого шлуночка (LV); правого шлуночка (RV) або міокарда лівого шлуночка (MYO) у діастолічній (ED) або систолічній (ES) фазах кардіоциклу.

Для проведення експериментів пропонується провести навчання *базової моделі* та ряду окремих *експериментальних моделей* для порівняння з нею.

Для проведення експериментів пропонується сформувати моделі:

1) M_1^{exp1} – базова модель, для навчання якої не будуть застосовуватися техніки попередньої обробки чи постобробки;

2) M_1^{exp2} – модель для локалізації сегмента серця (всіх структур одночасно) на МРТ-зображенні за оригінальною маскою;

3) M_2^{exp2} — модель для сегментації серця на окремі структури на локалізованому МРТ-зображенні за оригінальною (мультиструктурною) маскою;

4) M_1^{exp3} – модель для бінарної сегментації окремо лівого шлуночка на оригінальному МРТ-зображенні;

5) M_2^{exp3} – модель для бінарної сегментації окремо правого шлуночка на оригінальному МРТ-зображенні;

6) M_3^{exp3} – модель для бінарної сегментації окремо міокарда лівого шлуночка на оригінальному МРТ-зображенні.

Далі наведено опис та кроки навчання для кожної моделі окремо. Загалом навчання моделей проводиться з використанням підходів, запропонованих в основних кроках методу, тож для експериментальних моделей наведено лише загальні кроки та відмінності.

Навчання базової моделі сегментації МРТ-зображень

Для навчання базової моделі M_1^{exp1} не будуть застосовуватися техніки попередньої обробки вхідних даних (окрім обов'язкових як приведення зображення до єдиного розміру тощо), чи постобробки для покращення результатів. Мета цієї моделі — визначення базової здатності архітектури нейронної мережі до розпізнавання серцевих структур.

Вхідною інформацією є оригінальний набір даних D₁.

На *кроці 1* відбувається попередня (обов'язкова) обробка зображень з оригінального набору, а саме – приведення всіх вхідних зображень і масок до єдиного розміру за (2.3).

На *кроці* 2 здійснюється навчання моделі ГН M_1^{exp1} для виявлення області лівого і правого шлуночків та міокарда лівого шлуночка одночасно.

Вихідною інформацією є навчені моделі глибокого навчання M_1^{exp1} .

Навчання моделей для перевірки кроку попередньої локалізації

Для перевірки впливу кроку попередньої локалізації пропонується провести навчання двох моделей: моделі M_1^{exp2} – для локалізації всього сегмента серця на

МРТ-зображенні за оригінальною маскою та моделі M_2^{exp2} – для сегментації окремих серцевих структур на попередньо локалізованому зображенні.

Для навчання моделей використовуються певні кроки.

Вхідною інформацією є оригінальний набір даних D_1 .

На кроці 1 відбувається підготовка наборів даних:

- крок 1.1. Приведення всіх вхідних зображень і масок до єдиного розміру за (2.3);

– крок 1.2. Комбінування оригінальної мультиструктурної маски в єдину бінарну, яка описує все серце, за (2.10);

- крок 1.3. Локалізація маски та зображення за (2.8).

На кроці 2 відбувається навчання моделей:

– крок 2.1. Навчання ГН M_1^{exp2} для виявлення області серця на МРТзображенні;

– крок 2.2. Навчання ГН $M_2^{exp^2}$ для виявлення області лівого і правого шлуночків та міокарда лівого шлуночка одночасно на локалізованій області.

Вихідною інформацією є навчені моделі глибокого навчання $M_1^{exp^2}$ та $M_2^{exp^2}$. Навчання моделей для перевірки кроку декомпозиції

Для перевірки впливу кроку декомпозиції провести навчання трьох моделей: M_1^{exp3} – модель для бінарної сегментації окремо лівого шлуночка на оригінальному МРТ-зображенні, M_2^{exp3} – модель для бінарної сегментації окремо правого шлуночка на оригінальному МРТ-зображенні, M_3^{exp3} – модель для бінарної сегментації окремо правого шлуночка на оригінальному МРТ-зображенні.

Для навчання моделі M_1^{exp2} використовуються певні кроки.

Вхідною інформацією є оригінальний набір даних *D*₁.

На кроці 1 відбувається підготовка наборів даних:

- крок 1.1. Приведення всіх вхідних зображень і масок до єдиного розміру за (2.3);

- крок 1.2. Декомпозування оригінальної мультиструктурної маски в бінарні маски за (2.4).

На кроці 2 здійснюється навчання моделей.

- крок 2.1. Навчання ГН M_1^{exp3} для виявлення області лівого шлуночка;

- крок 2.2. Навчання ГН M_2^{exp3} для виявлення області правого шлуночка;

– крок 2.3. Навчання ГН M_3^{exp3} для виявлення області міокарда лівого шлуночка одночасно.

Вихідною інформацією є навчені моделі глибокого навчання M_1^{exp3} , M_2^{exp3} та M_3^{exp3} .

Таким чином, буде створено 6 додаткових моделей для проведення експериментів (M_1^{exp1} , M_1^{exp2} , M_2^{exp2} , M_1^{exp3} , M_2^{exp3} , M_3^{exp3}), у ході яких пропонується провести валідацію кроків методу для підтвердження доцільності їх окремого та комбінованого застосування.

2.1.4. Опис стратегії навчання моделей сегментації

Процес навчання нейронної мережі реалізовано у два етапи з використанням методології поетапного налаштування (progressive fine-tuning). Такий підхід дозволяє зберегти початкові знання попередньо навченої моделі, поступово адаптуючи їх до специфіки нового набору даних. Навчання відбувається у два етапи.

Під час першого етапу навчання оптимізація здійснюється із замороженими нижніми шарами, що означає, що коригуються лише верхні рівні нейромережі. Це дозволяє швидко адаптувати модель до нового завдання, не змінюючи основних низькорівневих ознак, які часто є універсальними для багатьох задач комп'ютерного зору. Тому це дозволить добре виявити чіткі форми і контури структур серця на МРТ-зображеннях. На цьому етапі пропонується використовувати відносно високу швидкість навчання (learning rate), щоб забезпечити ефективну початкову оптимізацію. З урахуванням наявної кількості даних це дозволить подібно та не сильно відрізняються за розміром та формою на всіх зображеннях, тому при високій швидкості навчання є ризик слабкої узагальненості та перенавчання.

Контроль за перенавчанням здійснюється за допомогою ранньої зупинки (patience), яка відбувається відразу після певної кількості епох без покращення функції втрат на валідаційному наборі, що дозволить завершити навчання після перших ознак імовірного перенавчання.

Після завершення першого етапу ваги мережі розморожуються, що дозволяє коригувати не лише верхні, а й нижні рівні моделі. Це забезпечує можливість більш точного налаштування всієї мережі під специфічні особливості нового набору даних. Проте, щоби уникнути значних змін у вже добре налаштованих шарах, пропонується застосовувати надзвичайно малу швидкість навчання. Це гарантує, що адаптація відбуватиметься дуже плавно, мінімізуючи ризик втрати вже сформованих вагових коефіцієнтів. Для цього етапу ранню зупинку пропонується змінити на більшу кількість епох, щоб мати можливість трохи довше продовжувати навчання, якщо функція втрат на валідаційному наборі продовжувала зменшуватися протягом кількох ітерацій, що можливо. Таким чином, навчальний процес розрахований на поступове удосконалення моделі, запобігаючи різким змінам у параметрах, які могли б спричинити втрату попередньо здобутих знань.

Ефективність обраної стратегії пояснюється кількома ключовими факторами. Поетапне налаштування дозволяє зберегти базові особливості, які були засвоєні на попередньому наборі даних, поступово адаптуючи їх під нові умови. Нижні рівні мережі, які на першому етапі залишалися незмінними, відповідають за обробку низькорівневих ознак, таких як контури, текстури та прості геометричні структури, такі як форма міокарда чи шлуночків. Оскільки ці характеристики є універсальними лля більшості зображень, ïχ збереження дозволяє моделі ефективно використовувати попередній досвід. Це дозволяє ефективно виділяти прості форми, зображенні. Верхні рівні шо добре вирізняються на мережі, навпаки, спеціалізуються на складніших закономірностях і є більш чутливими до варіацій у навчальному наборі. Саме тому їхнє первинне навчання з високою швидкістю дозволяє адаптувати модель до нового набору, а повне донавчання на другому етапі дає змогу більш детально коригувати загальну структуру ваг.

Застосування диференційованої швидкості навчання на різних етапах є ще одним важливим чинником ефективності цієї стратегії. Використання високої швидкості на першому етапі дозволяє моделі швидко зблизитися до оптимального рішення, тоді як зменшення швидкості на другому етапі запобігає руйнуванню вже знайдених оптимальних параметрів і дозволяє лише незначно коригувати їх для покращення узагальнення. Це дає змогу моделі уникнути явища катастрофічного забування (catastrophic forgetting), коли нові знання перекривають попередньо засвоєні закономірності.

Контроль за перенавчанням здійснювався через ранню зупинку, що дозволило зупинити навчання на момент, коли подальші ітерації не приносили значного покращення на валідаційному наборі. На першому етапі навчання використання ранньої зупинки запобігало надмірному підлаштуванню верхніх шарів під навчальні дані, тоді дещо збільшена рання зупинка на другому етапі дозволяла більш тривалий процес налаштування, що було необхідним з огляду на зменшену швидкість навчання. Поєднання цих двох параметрів гарантувало, що навчання тривало достатньо довго для отримання високої точності, але не настільки довго, щоб модель почала запам'ятовувати специфічні особливості навчального набору замість узагальнення закономірностей.

Розморожування після першого етапу відіграло ключову роль у підвищенні ефективності моделі. Під час першого етапу навчання було адаптовано лише верхні рівні, що дозволило швидко оптимізувати найчутливіші до змін шари. Однак нижні рівні, які залишалися замороженими, ще не були оптимально налаштовані для конкретного набору зображень. Їхнє розморожування дозволило здійснити більш точне налаштування, уникаючи значного втручання в уже здобуті знання. У результаті другий етап навчання забезпечив підвищення продуктивності моделі без ризику втрати її початкової генералізованої структури.

Таким чином, застосована стратегія навчання забезпечила оптимальний баланс між швидкістю адаптації та здатністю моделі до узагальнення, що дозволило ефективно використовувати обмежений набір зображень. Поєднання високої швидкості навчання на початковому етапі, поступового донавчання з низькою
швидкістю та використання ранньої зупинки дозволило досягти мінімізації функції втрат без надмірного перенавчання. Це підтверджується стабільним зменшенням функції втрат на валідаційному наборі протягом усього другого етапу та зростанням метрики класифікації, що вказує на покращення здатності моделі правильно розпізнавати нові зображення.

2.2. Метод каскадної класифікації МРТ-зображень

У цьому розділі представлено метод, який використовується для каскадної класифікації патологій на МРТ-зображеннях серця. Опис методу має таку структуру:

-ідея методу та модель подання – основні концепції методу, ключові міркування, припущення та особливості підходу, а також подання інформаційної моделі для вирішення задачі каскадної класифікації МРТ-зображень серця за патологіями;

- основні кроки методу: 1) формування моделей глибокого навчання;2) каскадна класифікація патологій.

Запропонований метод дозволяє ефективно класифікувати патології серця на основі МРТ-зображень, що сприяє автоматизації діагностичного процесу та підвищенню його точності.

2.2.1. Ідея методу та модель подання

До розгляду беруться чотири патології, за якими буде відбуватися класифікація МРТ-зображення: дилатаційна кардіоміопатія (DCM), гіпертрофічна кардіоміопатія (HCM), інфаркт міокарда зі зниженою фракцією викиду (MINF), аномальний правий шлуночок (ARV).

Пропонуються такі особливості запропонованого методу:

 врахування анатомічних параметрів серця шляхом певної модифікації вхідного зображення; використання одночасно МРТ-зображень діастолічної та систолічної фаз кардіоциклу;

використання каскадної моделі класифікації;

– оригінальна архітектура моделі глибокого навчання.

Обґрунтування запропонованих особливостей методу наведено далі.

Анатомічною особливістю визначення патологій серця за МРТ-зображеннями є врахування таких основних характерних рис: щільність та однорідність тканин серця, об'єми шлуночків та їх форма в динаміці, товщина та форма міокарда в динаміці. Виходячи з наведених особливостей, для визначення патологій засобами глибокого навчання, пропонується *врахувати анатомічні параметри серця шляхом певної модифікації вхідного зображення*. Для цього пропонується використовувати результати сегментації, отримані за наведеним раніше методом, що дозволить покращити результати класифікації.

Окрім зазначеного, пропонується використовувати одночасно *МРТ*зображення діастолічної та систолічної фаз кардіоциклу, оскільки аналіз роботи серця в цих фазах дозволяє оцінити його анатомічні та функціональні зміни, що є важливим для діагностики патологій.

Вибір 21 зрізу базується на тому, що це максимальна кількість зрізів, доступна в наборі даних. Таким чином, модель може враховувати повний обсяг інформації від пацієнтів з максимальною кількістю зрізів. Це дозволяє уникнути втрати даних, що могли б бути корисними для класифікації чи сегментації. Якщо пацієнт має менше зрізів, створення додаткових зрізів шляхом інтерполяції в іншому випадку системі доведеться приймати рішення для видалення якогось із зрізів, що може привести до втрати важливих даних та, відповідно, зменшить довіру до системи.

Отже, виходячи з наведених міркувань, пропонується таке відображення (декомпозиція) вхідного MPT-зображення:

$$F: I_{MRT} \to I_{MRT}^{new}, \tag{2.13}$$

де

$$I_{MRT}^{new} = (img_1, img_2, \dots, img_N,), N = 42,$$
(2.14)

тут

img₁ – img₂₁ – 21 МРТ-зображення (із зрізів вздовж короткої осі) зі систолічної фази; img₂₂ – img₄₂ – 21 МРТ-зображення (із зрізів вздовж короткої осі) зі діастолічної фази.

Далі наведено опис запропонованого подання більш детально.

Оскільки діагностично значущими є анатомічні особливості серця, такі як розміри шлуночків, товщина міокарда та інші геометричні параметри, для класифікації доцільно використовувати маски сегментації (які визначаються за допомогою попереднього методу багатоступеневої сегментації). Однак для деяких патологій необхідно враховувати неоднорідність тканин, що робить виключне використання масок недостатнім. Для вирішення цієї проблеми маски сегментації та МРТ-зображення об'єднуються таким чином, щоб забезпечити ефективне розпізнавання як геометричних ознак, так і текстурних особливостей. Для покращення сприйняття нейронною мережею, кожен сегмент серця (міокард, лівий і правий шлуночки) розміщується в окремих каналах кольорової моделі RGB. Це дозволяє представити різні анатомічні частини у вигляді окремих кольорових шарів, що забезпечує більш чітке розмежування структур між собою. Таким підходом вирішуються дві основні задачі: по-перше, нейронна мережа отримує можливість одночасно бачити всі три основні сегменти серця, що сприяє точнішому аналізу їхньої геометрії; по-друге, – враховуються текстурні неоднорідності тканин, що є важливими для діагностики певних патологій. Така комбінована подача даних сприяє кращому вивченню взаємозв'язків між анатомічними структурами та неоднорідною структурою тканин, що потенційно покращує результати класифікації патологій.

На рис. 2.12 продемонстровано зображення *img_i*, які будуть подаватись на вхід моделі глибокого навчання. Перший рядок – зображення із систолічної фази, другий рядок – зображення з діастолічної фази. Колонки – зрізи вздовж короткої осі. Червоним кольором позначені сегменти правого шлуночка, синім кольором – лівого шлуночка, зеленим кольором – сегмент міокарда.

Рис. 2.12 – Візуалізації вхідних даних

Для формування зображень img_i потрібно вхідні МРТ-зображення привести до одного розміру за (2.3) та обрізати, щоб залишилась лише область з необхідними сегментами (знайденими з допомогою методу багатоступеневої сегментації). При цьому важливо зберегти пропорції сегментів та відносне розташування у різних частинах серця та під час різних фаз кардіоциклу. Тому, на відмінну від локалізації зображень для сегментації (2.8), для класифікації необхідно знайти область (bounding box), яка вмістить всі сегменти на кожному із зрізів МРТ-зображення. Описані перетворення виконують за таким алгоритмом (функція *LocalizeAllImagesAndMasks*(*Imgs*, *Msks*)):

LocalizeAllImagesAndMasks(Imgs, Msks) 01 height, width ← get width, height from Imgs 02 maxMsk ← zeros(height, width)

 $03 \max Msk[i,j] \leftarrow 1$ **if** $Msks[k][i,j] \neq 0$

04 locImgs[i] ← LocalizeImageAndMask(Imgs[i], maxMsk, expand_coef) 05 locMsks[i] ← LocalizeImageAndMask(Msks[i], maxMsk, expand_coef) де вхідними даними є Msks – набір масок для кожного зрізу MPT, Imgs – набір зображень для кожного зрізу MPT; LocalizeImageAndMask – функція, описана в (2.8); zeros(height,width) – функція заповнення нулями, коефіцієнт для розширення рамки (expand_coef).

Далі інформація масок та зображень об'єднуються (функція IntegrateMasksToImages(Imgs, Msks)): IntegrateMasksToImages(Imgs, Msks) 01 for (Img, Msk) in (Imgs, Msks) do 02 height, width ← get width, height from Img

- 02 height, width \leftarrow get width, height from
- 03 intgImg \leftarrow zeros(height, width)
- 04 value \leftarrow Img[i,j]
- 05 intgImg[i,j] \leftarrow [value, 0, 0] if Msk[i,j] = 1
- 06 intgImg[i,j] \leftarrow [0, value, 0] if Msk[i,j] = 2
- 07 intgImg[i,j] \leftarrow [0, 0, value] if Msk[i,j] = 3

(2.15)

(2.16)

де вхідними даними є *Msks* – набір локалізованих масок для кожного зрізу MPT; *Imgs* – набір локалізованих зображень для кожного зрізу MPT; *zeros(height, width)* – функція заповнення нулями.

За запропонованим відображенням *F* (2.13) для навчання класифікаторів потрібно створити набір даних:

$$D_6 = \{d_1, d_2, \dots, d_N\}, d_i = (I_{MRI}^{new}, Cls), i = 1, 2, \dots, N,$$
(2.17)

де I_{MRI}^{new} –зображення за (2.14); Cls – клас патології; $Cls \in \{1,2,3,4,5\}$; тут 1 – аномальний правий шлуночок (abnormal right ventricle) (ARV); 2 – гіпертрофічна кардіоміопатія (hypertrophic cardiomyopathy) (HCM)№ 3 – інфаркт міокарда зі зниженою фракцією викиду (myocardial infarction, necrosis and fibrosis) (MINF); 4 – дилатаційна кардіоміопатія (dilated cardiomyopathy) (DCM); 5 – нормальний стан (NOR), N – кількість зразків у наборі даних.

Набір даних за структурою (2.17) пропонується отримати з набору даних Automated Cardiac Diagnosis Challenge (ACDC) [23], використовуючи метод багатоступеневої сегментації. Цей набір даних складається зі МРТ-зображень систолічної та діастолічної фаз 150 пацієнтів та містить 5 груп: 30 здорових пацієнтів; 30 пацієнтів з перенесеним раніше інфарктом міокарда; 30 пацієнтів з дилатаційною кардіоміопатією; 30 пацієнтів з гіпертрофічною кардіоміопатією; 30 пацієнтів з аномалією правого шлуночка.

Потрібно зазначити, що у наборі даних [37] не всі пацієнти мають по 21 МРТзображенню із зрізів вздовж короткої осі. Для подолання цієї проблеми запропоновано аугментацію МРТ-зображення між існуючими зрізами.

Для аугментації зображань розглядалися два такі підходи: 1) створити нове, апроксимоване зображення та маску, що буде «середньою» маскою та зображенням між двома сусідніми; 2) дублювати одну із сусідніх масок. У результаті проведених експериментів було виявлено, що жоден з підходів не має значної переваги на точність результатів, проте перший підхід є значно складнішим, оскільки генерується нове зображення та маска, що потребує додаткового доведення коректності отриманих апроксимованих даних. Отже, для апроксимації даних було обрано другий підхід, керуючись тим, що цей підхід зменшує складність системи та збільшує довіру до її результатів.

Зазначене пропонується реалізувати за таким перетворенням (функція *ApproximateArray(array, target_len)*):

ApproximateArray(array, target_len) 01 array_len ← len(array) 02 elements_count ← MIN(target_len - array_len, array_len)

04 sub_arrays ← numpy.array_split(array, elements_count)

06 for sub_array in sub_arrays do07 sub_array.append(sub_array[-1]) (duplicate last elem in each sub-array)(2.18)

08 result ← numpy.concatenate(sub_arrays)

09 **if** len(result) < target_len **then**

10 **return** ApproximateArray(array, target_len)

11 **else**

12 **return** result

де вхідними даними є *array* – масив елементів, в цьому випадку масок або зображень; *target_{len}* – очікувана кінцева кількість елементів; *numpy.array_{split}* – функція для розділення масиву на підмасиви; *numpy.concatenate* – функція для об'єднання підмасивів у масив.

У методі пропонується *використати каскадну модель класифікації*. Обґрунтуванням використання каскадного підходу є те, що при використанні невеликих наборів даних складно досягнути достатньої узагальненості моделі для всіх класів, що спричиняє їх сплутування. Використання каскаду окремих бінарних класифікаторів дозволить моделі глибокого навчання під час навчання (виявлення прихованих залежностей):

- збільшити кількість зразків для кожного агрегованого клас;

– зосередитися на конкретних особливостях двох агрегованих класів, що приведе до збільшення точності класифікації.

Запропоновано такі моделі глибокого навчання для класифікації (з агрегацією класів *Cls* із набору даних *D*₆ (2.17):

- *M*₇ - клас *a* - агрегація класів 1 та 5, клас *b* - агрегація класів 2,3 та 4;

- *M*₈ - клас *a* - клас 1, клас *b* - клас 5;

 $- M_9$ – клас a – клас 2, клас b – агрегація класів 3 та 4;

 $- M_{10} -$ клас a -клас 4, клас b -клас 3.

Структура запропонованої каскадної класифікації зображена рис. 2.13.



Рис. 2.13 – Структура каскадної класифікації, де ARV, HCM, MINF, DCM, NOR – відповідні класи, патології ЛШ – HCM, MINF, DCM

Далі наведено аргументацію запропонованого поділу.

 M_7 відокремлює патології лівого шлуночка (класи 2, 3 та 4) та решту можливих варіантів, включаючи патології правого шлуночка і нормальний стан пацієнта (класи 1 та 5). Це дозволяє моделі глибокого навчання ігнорувати деталі кожної патологій, та зосередитися лише на загальних ознаках для виявлення наявності або відсутності патологій лівого шлуночка.

 M_8 розділяє виявлені за M_7 класи (аномальний правий шлуночок та нормальний стан, класи *1* та *5*) на два підкласи. Відділення цих класів від патологій лівого шлуночка дозволяє моделі глибокого навчання краще зосередитися на особливостях патологій правого шлуночка та краще відділити їх від нормального стану.

 M_9 здійснює розділення виявлених на першому кроці патологій лівого шлуночка на два підкласи: гіпертрофічну кардіоміопатію (клас 2) та решту патологій лівого шлуночка (класи 3 та 4). Модель глибокого навчання зосереджується на специфічних ознаках гіпертрофічної кардіоміопатії, дозволяючи краще ідентифікувати цей тип патології.

 M_{10} розділяє решту патологій лівого шлуночка на патології попереднього інфаркту міокарда (клас 3) та дилатаційну кардіоміопатію (клас 4). Ці два класи мають певні подібні ознаки, тому є ризик сплутування цих класів. Тому окрема класифікація дозволяє зосередитися моделі глибокого навчання на особливостях цих класів та краще розділити їх між собою.

Для M_7 , M_8 , M_9 та M_{10} запропоновано використовувати архітектуру глибокого навчання у вигляді згорткової нейронної мережі (CNN), адаптованої для задачі бінарної класифікації. Архітектура запропонованої нейромережі схематично зображена на рис. 2.14.





Архітектура нейромережі має 50 шарів та включає кілька ключових компонентів, таких як початковий шар згортки для витягнення базових ознак, шари нормалізації та активації для стабілізації процесу навчання, а також згорткові блоки

із залишковими зв'язками. Перший шар (Conv1) використовує великі фільтри для початкового витягнення базових ознак, таких як контури та текстури. Далі, блоки Conv2, Conv3, Conv4, і Conv5 складаються з послідовностей операцій згортки з різними розмірами фільтрів. Ці блоки дозволяють моделі вивчати дедалі складніші та більш абстрактні ознаки на кожному етапі. Кожен наступний блок глибше аналізує вхідні дані, а кількість фільтрів зростає, що дозволяє моделі розрізняти все більш складні структури. Після завершення всіх згорткових операцій використовується глобальний середньозважений пулінг, який об'єднує всі отримані ознаки в один узагальнений вектор. Цей вектор подається на останній шар, який відповідає за остаточну класифікацію на два класи. Завдяки такій багаторівневій обробці зображень модель здатна аналізувати вхідні дані від простих деталей до складних патернів, що робить її ефективною для задачі класифікації.

Також пропонується використовувати оптимізатор Adam [129] та функцію втрат «categorical crossentropy» [130]. Adam (Adaptive Moment Estimation) – це алгоритм, який оновлює ваги моделі, намагаючись зменшити помилку (втрату) між прогнозами моделі та реальними результатами. Adam адаптивно змінює швидкість навчання для кожного параметра, що допомагає підтримувати стабільність та швидко сходиться до оптимального результату. Функція втрат «categorical crossentropy» використовується для оцінки, наскільки добре модель передбачає правильний клас. Це дозволяє вимірювати розбіжність між реальними мітками класів і передбаченими ймовірностями. Іншими словами, вона показує, наскільки впевнено модель робить правильний або неправильний вибір.

Отже, використання оптимізатора та функції втрат дозволяє точно оцінювати якість передбачень, вимірюючи розбіжність між реальними мітками та передбаченими ймовірностями, що допомагає моделі поступово покращувати свої результати у задачах класифікації.

Також пропонується розділяти набір даних на навчальну та валідаційну вибірки, зберігаючи при цьому пропорції класів. Під час навчання пропонується застосувати механізм ранньої зупинки для запобігання перенавчанню, який зупиняє навчання, якщо валідаційні втрати не покращуються.

2.2.2. Основні кроки методу

Основні кроки методу можна розділити на два етапи: кроки для навчання моделей глибокого навчання та кроки для класифікації патологій.

Кроки для отримання моделей глибокого навчання

У підрозділі розглянуто процес навчання моделей M_7 , M_8 , M_9 та M_{10} . Загальна схема цього процесу зображена на рис. 2.15.



Рис. 2.15 – Загальна схема процесу навчання моделей M_7 , M_8 , M_9 та M_{10} .

Вхідною інформацією є зображення з набору даних D_6 , що модифіковані наведеним вище чином, і які містять зображення для кожного пацієнта в моменти діастолічної та систолічної фаз кардіоциклу.

Крок 1. Підготовка МРТ-зображень:

– крок 1.1. Всі МРТ-зображення обрізаються, щоб залишити лише область з необхідними сегментами (знайденими за допомогою першого методу) та приводяться до єдиного розміру за (2.4); *– крок 1.2.* Маски та зображення об'єднуються (кожен сегмент серця відповідно до маски подається в окремому каналі, як описано вище за (2.5));

– крок 1.3. Дані зображень та масок аугментуються для отримання однакової кількості елементів для кожного пацієнта за (2.7);

– крок 1.4. Маски та зображення з діастолічної та систолічної фаз кардіоциклу об'єднуються, як представлено в (2.16).

Крок 2. Навчання каскаду з 4-х класифікаторів. Кожен класифікатор навчається окремо з використанням однакового підходу. Процес навчання починається зі створення та компіляції моделі за архітектурою, що була описана вище:

- крок 2.1. Навчання моделі класифікатора M₇;

- крок 2.2. Навчання моделі класифікатора *M*₈;

- крок 2.3. Навчання моделі класифікатора M₉;

- крок 2.4. Навчання моделі класифікатора M₁₀.

Вихідною інформацією методу є навчений каскад класифікаторів з 4-х класифікаторів M_7, M_8, M_9 та M_{10} .

Кроки для класифікації патологій за МРТ-зображеннями

У підрозділі розглянуто процес класифікації патології за довільним МРТзображенням серця. На рис. 2.16 зображена схема зазначеного процесу.

Вхідною інформацією є набір МРТ-зображень довільного пацієнта, що містить знімки в моменти діастолічної та систолічної фаз кардіоциклу.

Крок 1. Підготовка МРТ-зображень:

 – крок 1.1. Всі МРТ-зображення обрізаються, щоб залишити лише область з необхідними сегментами (знайденими з допомогою першого методу) та приводяться до єдиного розміру за (2.4);

– крок 1.2. Сегментація всіх зображень пацієнта за методом багатоступеневої сегментації МРТ-зображень, описаного в розділі 2.1;

- крок 1.3. Дані зображень та отриманих масок об'єднуються (кожен сегмент серця відповідно до маски подається в окремому каналі, як описано вище за (2.5));

– крок 1.4. Дані зображень та масок аугментуються для отримання кількості елементів відповідно до навченої моделі (21 зображення) за (2.7);

– крок 1.5. Маски та зображення з діастолічної та систолічної фаз кардіоциклу об'єднуються, як представлено в (2.16).



Рис. 2.16 – Схема процесу класифікації патології довільного пацієнта за МРТ-зображеннями серця

Крок 2. Застосування каскаду класифікаторів для визначення патологій:

- крок 2.1. Застосування класифікатора *M*₇;

– крок 2.2. Якщо результат класифікації за М₇ відповідає класу *а* – застосування класифікатора М₈;

– крок 2.3. Якщо результат класифікації за М₇ відповідає класу *b* застосування класифікатора М₉;

– крок 2.4. Якщо результат класифікації за М₉ відповідає класу а застосування класифікатора М₁₀.

Вихідною інформацією методу є визначена одна з патологій:

1. Аномальний правий шлуночок (abnormal right ventricle – ARV);

2. Гіпертрофічна кардіоміопатія (hypertrophic cardiomyopathy) (HCM);

3. Інфаркт міокарда зі зниженою фракцією викиду (myocardial infarction, necrosis and fibrosis) (MINF);

4. Дилатаційна кардіоміопатія (dilated cardiomyopathy) (DCM);

5. Нормальний стан (NOR).

2.3. Висновки до розділу 2

Розроблений метод багатоступеневої сегментації дозволяє виділяти ключові області серця, такі як лівий і правий шлуночки та міокард. Використання окремих моделей глибокого навчання для кожної області забезпечує більш точне визначення контурів цих структур. Для цього було застосовано архітектуру U-Net з ResNet-50 для локалізації та ResNet-34 для визначення контурів, що дозволяє досягти балансу між якістю результату та обчислювальними витратами. Додатково було створено модифіковані набори даних шляхом попередньої обробки оригінальних зображень і масок, що забезпечило узгодженість даних і підвищило ефективність навчання моделей.

Метод каскадної класифікації базується на використанні чотирьох бінарних класифікаторів, кожен з яких вирішує окреме завдання. Такий підхід дозволяє поетапно розділяти класи, зосереджуючи увагу моделей на специфічних особливостях двох агрегованих класів на кожному етапі класифікації. Це сприяє зниженню ризику плутанини між класами в умовах обмеженого обсягу даних. Крім того, у процесі класифікації враховуються анатомічні особливості серця, такі як геометрія шлуночків, товщина міокарда та текстурні характеристики тканин, що забезпечує більш глибокий аналіз патологій.

Таким чином, завдяки використанню багатоступеневої сегментації та каскадної класифікації модель здатна враховувати складні анатомічні та функціональні особливості серця, що є важливими для визначення патологій.

РОЗДІЛ 3.

МЕТОД ІНТЕРПРЕТАЦІЇ ОТРИМАНИХ ЗА МОДЕЛЯМИ ГЛИБОКОГО НАВЧАННЯ РІШЕНЬ

У розділі буде розглянуто метод для вирішення проблеми цьому пояснюваності (інтерпретованості) моделей ШІ, яка є дуже чутливою для предметної області медицини, оскільки непрозорість процесів прийняття рішень моделями ШІ створює ефект «чорної скрині», що значно знижує довіру лікарів до отриманих результатів. Це особливо актуально для діагностики серцево-судинних захворювань, які потребують глибокого аналізу та врахування специфічних медичних ознак. У дослідженні запропоновано подавати результати, отримані за моделями глибокого навчання, у вигляді, зрозумілому лікареві, а саме – за допомогою ознак, які він розуміє. Це дозволяє вирішувати низку важливих технічних, моральних та юридичних питань, які виникають під час впровадження штучного інтелекту в медичну практику.

З технічної точки зору, метод спрямований на подолання проблем пояснюваності моделей ШІ, які часто сприймаються як «чорна скриня». Це суттєво знижує довіру лікарів до результатів аналізу, особливо у критичних галузях, таких як діагностика серцево-судинних захворювань. Запропонований підхід забезпечує представлення результатів у вигляді числових і графічних ознак, зрозумілих медичним спеціалістам. Наприклад, замість суб'єктивної оцінки нерівномірності стінки міокарда лікар отримує стандартизований числовий показник, як-от середнє стандартне відхилення товщини міокарда в кінцевій систолі. Це дозволяє перейти від суб'єктивних спостережень до об'єктивних даних, які підвищують точність діагностики, стандартизують процес аналізу та мінімізують ризик помилок.

Забезпечені прозорості рішень, які приймає система ШІ, також покриває моральні аспекти застосування ШІ в медицині. Пацієнт має моральне право розуміти, як було сформульовано діагноз або запропоноване лікування, а лікарі мають моральне право зберігати контроль над прийняттям клінічних рішень. Важливо чітко визначити, хто відповідає за рішення – ШІ чи лікар. Метод

інтерпретації забезпечує передачу відповідальності лікарю, надаючи йому всі необхідні інструменти для аналізу. Інтерпретований метод гарантує, що ШІ не замінює лікаря, а надає інструменти для верифікації результатів. Це дозволяє йому залишатися основною відповідальною особою за здоров'я пацієнта, що є етично обґрунтованим підходом та гарантує, що рішення ухвалюється професіоналом, а не автоматичною системою, що відповідає моральним вимогам до використання ШІ.

Представлення результатів у числовому та графічному вигляді, окрім того, що дозволяє забезпечити прозорість процесу аналізу, відкриває можливості для якісного документування результатів. Запис числових показників дає змогу відтворити аналіз за схожих умов, що важливо для стандартизації медичних практик і контролю якості. Також лікар може переглянути конкретні дані, які стали основою класифікації. ЩО створює можливість для незалежної перевірки для та підтвердження результатів. У разі виникнення юридичних питань, пов'язаних з точністю або обґрунтованістю діагностики, задокументовані результати можуть слугувати доказом прозорості процесу прийняття рішення. Чітке представлення числових і графічних даних допоможе підтвердити, що рішення було прийняте на основі об'єктивної інформації, а не суб'єктивної інтерпретації моделі.

Розділ також висвітлить методи формування числових і візуальних представлень цих ознак, що дозволяють лікарям оцінити результати аналізу та перевірити їх відповідність клінічним спостереженням. Таким чином, буде продемонстровано, як інтерпретовані рішення можуть підвищити довіру до технологій ШІ та забезпечити їх інтеграцію у сучасну медицину.

3.1. Ідея методу

Базові міркування та пропозиції, на яких побудована основна ідея методу, яка відрізняє його від подібних і полягає у тому, щоб надавати лікареві, крім безпосередньо результату визначення патології за аналізом МРТ-моделями глибокого навчання, ще й значення показників (ознак), які або підтвердять його, або ні (таке також може бути, навіть при таких досить високих показниках точності навчання класифікатора) полягають в такому:

1. Варто зазначити, що визначення наведених вище ознак лікарем має певну суб'єктивність. Для об'єктивної медичної діагностики важливо перейти від його суб'єктивних спостережень до об'єктивних числових показників, які дозволять стандартизувати аналіз. Наприклад, візуально виявлена нерівномірність стінки міокарда, яка може вказувати на патологічні зміни, може бути представлена числовими значеннями, такими як середнє стандартне відхилення товщини міокарда в кінцевій систолі. Такий показник об'єктивно відображає варіабельність товщини стінки, що знижує ризик суб'єктивних помилок і дозволяє порівнювати результати між пацієнтами. Впровадження конкретних числових показників для опису медичних ознак забезпечує більшу точність і надійність діагнозу, а також відкриває можливості для об'єктивної оцінки прийнятих рішень, отриманих за результатами використання методів ШІ.

2. Крім того, варто зазначити, що бажано використовувати саме ті числові показники, для представлення перелічених груп медичних ознак, які вже де-факто, використовуються для подібних цілей. Виходячи з цього, у роботі запропоновано використовувати такі показники [133]:

1. Кінцевий діастолічний об'єм лівого шлуночка.

2. Кінцевий систолічний об'єм лівого шлуночка;

3. Кінцевий систолічний об'єм правого шлуночка;

4. Кінцевий діастолічний об'єм правого шлуночка;

5. Фракція викиду лівого шлуночка;

6. Фракція викиду правого шлуночка;

7. Маса міокарда в кінцевій діастолі;

8. Маса міокарда в кінцевій систолі;

9. Середнє стандартне відхилення товщини стінки міокарда в кінцевій систолі;

10. Середнє стандартне відхилення товщини стінки міокарда в кінцевій діастолі;

11. Максимальна середня товщина стінки міокарда в кінцевій діастолі;

12. Максимальна середня товщина стінки міокарда в кінцевій систолі;

13. Співвідношення маси міокарда до кінцевого діастолічного об'єму лівого шлуночка;

14. Співвідношення маси міокарда до кінцевого систолічного об'єму лівого шлуночка;

15. Співвідношення кінцевого діастолічного об'єму лівого шлуночка до кінцевого діастолічного об'єму правого шлуночка.

3. Варто зазначити, що присутність у запропонованому підході методу сегментації МРТ-зображення, який значно покращив точність сегментації та зменшив артефакти зображення, дозволяє більш точно визначати числові значення наведених ознак.

4. Пропонується надавати лікареві зазначені ознаки як у числовому, так і у графічному виглядах, що застосовуються в медичній практиці.

3.2. Модель інтерпретації та візуалізації

На (3.1) наведено інформаційну модель з використанням множини ознак (3.2) для запропонованої інтерпретації рішень, отриманих за моделями глибокого навчання, за допомогою відображень F_d , d = 1,2,3,4,5 (2.8):

$$F_d: I \to O_d, \tag{3.1}$$

де *d* – патологія (1 – DCM (дилатаційна кардіоміопатія); 2 – HCM (гіпертрофічна кардіоміопатія); 3 – MINF (інфаркт міокарда зі зниженою фракцією викиду); 4 – ARV (Аномальний правий шлуночок); 5 – NOR (нормальний стан); *I* – сегментоване, за допомогою методу сегментації МРТ-зображення; *O_d* – множина ознак, для патології *d*:

$$O_d = \{o_1^d, o_2^d, \dots, o_{N_d}^d\}, o_i^d = (name, type_j), i = 1, 2, \dots, N_d, j = 1, 2, 3,$$
(3.2)

де N_d – кількість ознак для патології d; name – назва ознаки; $type_j$ – вид подання ознаки:

*type*₁ – представлення у вигляді 17-сегментної моделі міокарда [134] (для показників, пов'язаних з товщиною міокарда, наприклад, максимальна середня товщина стінки міокарда в кінцевій діастолі);

*type*₂ – представлення у вигляді кругової діаграми (для наочного зображення показників співвідношень, наприклад, співвідношення об'єму лівого шлуночка до об'єму правого шлуночка);

*type*₃ – представлення у числовому вигляді, наприклад, об'єм міокарда в кінці систоли.

Далі наведено показники для кожної патології разом з рекомендованими методами візуалізації.

d = 1 - DCM, дилатаційна кардіоміопатія:

 $o_1^1 = ($ кінцевий діастолічний об'єм лівого шлуночка, $type_3$);

 $o_2^1 = ($ кінцевий систолічний об'єм лівого шлуночка, $type_3);$

 $o_3^1 = (фракція викиду лівого шлуночка, <math>type_3);$

 $o_4^1 = ($ маса міокарда в кінцевій діастолі, $type_3);$

 $o_5^1 = ($ співвідношення маси міокарда до кінцевого діастолічного об'єму лівого шлуночка, $type_2$);

 $o_6^1 = ($ максимальна середня товщина стінки міокарда в кінцевій діастолі, $type_1$);

d = 2 - HCM, гіпертрофічна кардіоміопатія:

 $o_1^2 = ($ кінцевий систолічний об'єм лівого шлуночка, $type_3);$

 $o_2^2 = (фракція викиду лівого шлуночка, type_3);$

 $o_3^2 = ($ співвідношення маси міокарда до кінцевого систолічного об'єму лівого шлуночка, $type_2$);

 $o_4^2 = ($ максимальна середня товщина стінки міокарда в кінцевій діастолі, $type_1$);

 o_5^2 = (середнє стандартне відхилення товщини стінки міокарда в кінцевій систолі, $type_3$);

 o_6^2 = (середнє стандартне відхилення товщини стінки міокарда в кінцевій діастолі, $type_3$);

d = 3 - MINF, інфаркт міокарда зі зниженою фракцією викиду:

 $o_1^3 = ($ кінцевий діастолічний об'єм лівого шлуночка, $type_3$);

 $o_2^3 = (фракція викиду лівого шлуночка, type_3);$

 $o_3^3 = ($ маса міокарда в кінцевій діастолі, $type_3);$

 $o_4^3 = ($ максимальна середня товщина стінки міокарда в кінцевій діастолі, $type_1$);

 o_5^3 = (середнє стандартне відхилення товщини стінки міокарда в кінцевій діастолі, *type*₃);

d = 4 - ARV, аномальний правий шлуночок:

 $o_1^4 = ($ кінцевий діастолічний об'єм правого шлуночка, $type_3$);

 $o_2^4 = (фракція викиду правого шлуночка, <math>type_3);$

 o_3^4 = (співвідношення кінцевого діастолічного об'єму лівого шлуночка до кінцевого діастолічного об'єму правого шлуночка, $type_2$);

 $o_4^4 = ($ максимальна середня товщина стінки міокарда в кінцевій систолі, $type_1$);

 o_5^4 = (середнє стандартне відхилення товщини стінки міокарда в кінцевій систолі, $type_3$).

d = 5 - NOR, нормальний стан:

 $o_1^5 = ($ кінцевий систолічний об'єм лівого шлуночка, $type_3);$

 $o_2^5 = ($ кінцевий діастолічний об'єм лівого шлуночка, $type_3);$

 o_3^5 = (співвідношення кінцевого діастолічного об'єму лівого шлуночка до кінцевого діастолічного об'єму правого шлуночка, $type_2$);

 $o_4^5 = (\phi paкція викиду лівого шлуночка, type_3);$

 $o_5^5 = ($ максимальна середня товщина стінки міокарда в кінцевій систолі, $type_1$);

Приклад представлення окремих видів ознак наведено на рис. 3.1, де a - 17сегментна модель міокарда ($type_1$) [134] з підсвіченням значення товщини для 16-го сегменту; b – візуалізація зрізу, що містить обраний (16-й) сегмент і дозволяє лікарю самостійно оцінити необхідну частину серця; c – кругова діаграма ($type_2$), що відображає співвідношення показників, які лікарю необхідно оцінити відносно один одного; d – подання числових значень необхідних для аналізу конкретної патології у вигляді таблиці ($type_3$).





Кінцевий систолічний об'єм ЛШ	13 мл
Фракція викиду ЛШ	70%
Відхилення товщини стінки міокарда (ES)	2.315
Відхилення товщини стінки міокарда (ED)	0.002

(d)

(b)

Рис. 3.1 – Види подання ознак

Як видно з наведеного, для кожної ознаки, що відноситься до певних груп (об'єми серця, фракція викиду, співвідношення об'ємів та маси, товщина стінок міокарда) були застосовані окремі підходи до візуалізації. Для ознак, пов'язаних із співвідношеннями, запропоновано подання у вигляді кругових діаграм для наочного порівняння показників. Товщина та варіабельність стінок міокарда відображені у 17сегментній моделі міокарда, що дозволяє оцінити ці ознаки за одним зображенням без необхідності порівняння різних зрізів МРТ-зображення. Числові значення застосовані для таких ознак, як об'єм міокарда в різні фази серцевого циклу, що спрощує інтерпретацію даних лікарями.

Запропонована модель для візуалізації та інтерпретації дозволяє подати результати класифікації у формі, яка використовується в медичній практиці та є інтуїтивно зрозумілою для лікарів. Така форма подання сприяє наочному розумінню результатів та допомагає лікарю оцінити рішення, прийняті за моделями глибокого навчання, у контексті клінічної практики.

3.3. Способи отримання значень ознак

Ознаки o_1^1, o_1^3 розраховують для зображень кінцевої діастоли за (3.3) для сегментів лівого шлуночка, а ознаки o_2^1, o_1^2 – для зображень кінцевої систоли за (3.3) для сегментів лівого шлуночка. o_1^4 розраховується для зображень кінцевої систоли за (3.3) для сегментів правого шлуночка:

$$V_{s} = \sum_{i=1}^{n} (A_{i}^{s} \cdot t)$$
(3.3)

де V_s — об'єм s; A_i^s — площа контуру s для *i*-го зрізу; $s \in \{LV - n$ івий шлуночок, RV — правий шлуночок }; n — кількість зрізів у МРТ-зображенні; t — товщина зрізу (надається в метаданих МРТ-зображення) [135].

Ознаки o_3^1, o_2^2, o_2^3 розраховують з використанням зображень кінцевої систоли та діастоли за (3.4) для сегментів лівого шлуночка. Ознака o_2^4 розраховується з використанням зображень кінцевої систоли та діастоли за (3.4) для сегментів правого шлуночка:

$$F = \frac{V_{ED} - V_{ES}}{V_{ED}} \cdot 100$$
(3.4)

де *F* – фракція викиду (%); *V_{ED}* – систолічний об'єм за (3.1); *V_{ED}* – діастолічний об'єм за (3.1) [135].

Ознаки o_4^1, o_3^3 розраховують для зображень кінцевої систоли (3.3) за сегментами міокарда:

$$M_{MYO} = V_{MYO} \cdot \rho_{MYO} \tag{3.5}$$

де M_{MYO} – маса міокарда; V_{MYO} – об'єм міокарда за (3.1); ρ_{MYO} – щільність тканини міокарда (для розрахунку приймається 1.05 г/см³) [135].

Ознака o_5^1 розраховується для зображень кінцевої діастоли за (3.6) за сегментами лівого шлуночка та міокарда; ознака o_3^2 – для зображень кінцевої систоли за (3.6) за сегментами лівого шлуночка та міокарда.

$$R_1 = \frac{M_{MYO}}{V_{LV}} \tag{3.6}$$

де R_1 – співвідношення маси міокарда до об'єму лівого шлуночка M_{MYO} ; V_{LV} – об'єм міокарда за (3.1) [20].

Ознака o_3^4 розраховується для зображень кінцевої діастоли за (3.7) за сегментами лівого та правого шлуночків:

$$R_2 = \frac{V_{LV}}{V_{RV}} \tag{3.7}$$

де R_1 – співвідношення об'єму лівого шлуночка до об'єму правого шлуночка; V_{LV} – об'єм лівого шлуночка за (3.1); V_{RV} – об'єм правого шлуночка за (3.1) [20].

Для ознак типу $type_1$ необхідно розрахувати товщину стінок міокарда. Товщина стінок міокарда визначається як перпендикулярна відстань між ендокардіальним (внутрішня межа міокарда, що межує з порожниною шлуночка) і епікардіальним (зовнішня межа міокарда, що межує з перикардом) контурами в певній зоні міокарда (рис. 3.2):

$$T_{myo} = d(E, P) \tag{3.8}$$

де T_{myo} – товщина стінки міокарда в конкретній точці; d(E, P) – перпендикулярна відстань між ендокардіальною *E* та епікардіальною *P* контурами.



Рис. 3.2 – Візуалізація заміру товщини стінки міокарда в конкретній зоні: *Р* – точка на епікардіальному контурі міокарда;

E – точка на ендокардіальному контурі міокарда; *C* – центр маси лівого шлуночка; відрізок *E*–*P* – відрізок; довжина якого представляє товщину стінки міокарда. Необхідні розрахунки пропонується виконувати за допомогою підходу, який грунтується на використанні полярної системи координат для трансформації зображення серця. Підхід дозволяє працювати з круговими (концентричними) структурами шляхом переведення їх із декартової системи координат у полярну. У такому вигляді зображення стає зручним для аналізу, оскільки контури міокарда розгортаються в лінійній площині, що спрощує обчислення товщини стінок серця. Основна ідея полягає в тому, щоб перетворити координати кожної точки зображення, враховуючи її відстань від центра (радіус) і положення за кутом, та отримати двовимірну матрицю, де кожен стовпець відповідає певному куту, а кожен рядок – радіальному значенню. Такий підхід дозволяє розраховувати товщину міокарда як відстань між епікардіальним і ендокардіальним контурами. Приклад такого перетворення зображено на рис. 3.3 (трансформація та обчислення проводяться для маски, оскільки вона має інформацію про розмічені контури; на рисунку використовується MPT-зображення для кращої наочності описаних операцій).



Рис. 3.3 – Приклад трансформації з використанням полярної системи координат: *a* – приклад вхідного зображення з відображенням сітки полярної системи координат; *б* – трансформоване зображення; *в* – обрізане трансформоване зображення відносно маски; *г* – обрізана трансформована маска

Підхід складається з двох основних кроків: розгортання маски та обчислення товщини міокарда для кожного кута.

Крок 1. Розгортання маски з використанням полярної системи координат. Необхідні пропонується реалізувати перетворення таким чином (функція RemapToPolar(Mask)):

RemapToPolar(Mask) 01 height, width \leftarrow get heught and weight of Mask 02 center \leftarrow (width / 2, height / 2) 03 max radius \leftarrow numpy.sqrt(center.x² + center.y²) 04 polar image \leftarrow numpy.zeros(max radius, 360)

05 for angle in range(0, 360) do 06 **for** radius **in** range(0, max_radius) **do**

07

 $x \leftarrow radius * numpy.cos(np.deg2rad(angle)) + center.x$ $y \leftarrow radius * numpy.sin(np.deg2rad(angle)) + center.y$ 08

09 polar image[radius, angle] \leftarrow image[y, x]

10 **return** polar_image

де вхідними даними є *Mask*, локалізована маска за *numpy.sqrt* – функція для обчислення квадратного кореня, *numpy.zeros* – функція для заповнення масиву нулями, *numpy.cos* – функція для обчислення косинуса, *numpy.sin* – функція для обчислення синуса, numpy.deg2rad – функція для перетворення кутів з градусів на радіани.

У новій системі координат радіуси (від 0 до максимального значення, що відповідає відстані від центра до найдальшої точки зображення) формують вертикальну ось, а кути (від 0° до 360°) – горизонтальну. Це дозволяє перетворити кругову форму серця на лінійне представлення, де кожен піксель розташовується відповідно кута. У такому ДО свого радіального значення та форматі ендокардіальний і епікардіальний контури стають двома горизонтальними лініями, що значно спрощує їхню обробку. Завдяки цьому товщину міокарда можна визначати як просту різницю між координатами цих ліній у кожному стовпці зображення. Додатковою перевагою є можливість аналізу змін товщини по всій окружності серця, що важливо для діагностики локальних патологій, таких як гіпертрофія або стоншення стінок міокарда.

Крок 2. Розрахунок товщини міокарда. Для обчислення товщини міокарда на кожному напрямку (кожному куті) обирається відповідний стовпець. У ньому

(3.9)

видаляються всі нульові значення, що представляють відсутність даних поза межами міокарда, а кількість ненульових пікселів, що залишилася, представляє товщину міокарда. Зазначене пропонується реалізувати таким чином (функція *CalculateMWT(Image)*):

CalculateMWT(Mask) 01 polar_mask ← RemapToPolar(Mask)

```
02 mwts ← []

03 for i from 0 to 360 do

04 column_trim ← numpy.trim_zeros(polar_mask[:, i])

05 mwt ← len(column_trim)

06 mwts.append(mwt)
```

07 return mwts

де вхідними даними є Mask, локалізована маска за (2.8); RemapToPolar – функція трансформації зображення в полярну форму, описана в (3.9); numpy.trim_zeros – функція видалення нулів з масиву.

Описане можна подати з допомогою таких формул:

$$T_{myo} = \{T_{myo}^{1}, T_{myo}^{2}, ..., T_{myo}^{i}\},\$$

$$T_{myo}^{i} = \{T_{myo}^{i,1}, T_{myo}^{i,2}, ..., T_{myo}^{i,\theta}\},\$$

$$T_{myo}^{i,\theta} = R_{epi}^{i,\theta} - R_{endo}^{i,\theta},\$$

$$i \in \{1, 2, ..., 21\}, \theta \in \{1, 2, ..., 360\}$$
(3.11)

де T_{myo} – множина товщин міокарда для всіх МРТ-зображень пацієнта певної фази кардіоциклу; T_{myo}^{i} – множина товщин міокарда на кожному напрямку (кожному куті) для певного *i*-го зрізу МРТ-зображення; $T_{myo}^{i,\theta}$ – товщинна міокарда в конкретному куті θ ; R_{epi}^{θ} та R_{endo}^{θ} – радіуси епікардіального та ендокардіального контурів для кута θ .

Отже, враховуючи описане вище, решту ознак розраховують певним чином.

Ознаки o_6^1, o_4^2, o_4^3 розраховуються з використанням зображень кінцевої діастоли, ознака $o_4^4 - 3$ використанням зображень кінцевої систоли:

$$MaxMean_{myo} = max\left(\frac{\sum_{\theta=1}^{360} T_{myo}^{i,\theta}}{360}\right)$$
(3.12)

(3.10)

де $MaxMean_{myo}$ — максимальне середнє значення товщини міокарда серед усіх зрізів; $T^{i,\theta}_{myo}$ — товщина міокарда на *i*-му зрізі у напрямку кута θ .

Ознаки o_5^2 , o_5^4 розраховуються з використанням зображень кінцевої систоли, ознаки o_6^2 , o_5^3 – з використанням зображень кінцевої діастоли:

$$MeanStd_{myo} = \frac{\Sigma_{i=1}^{n}\sigma_{i}}{n},$$

$$\sigma_{i} = \sqrt{\frac{\left(\Sigma_{\theta=1}^{360}\left(T_{myo}^{i,\theta} - \bar{T}_{myo}^{i}\right)^{2}\right)}{360}},$$

$$\bar{T}_{myo}^{i} = \frac{\Sigma_{\theta=1}^{360}T_{myo}^{i,\theta}}{360}$$
(3.13)

де $MeanStd_{myo}$ – середнє стандартне відхилення товщини міокарда по всіх зрізах, σ_i – стандартне відхилення товщини міокарда на *i*-му зрізі; $T^{i,\theta}_{myo}$ – товщина міокарда на *i*-му зрізі у напрямку кута θ ; \bar{T}^i_{myo} – середня товщина міокарда на *i*-му зрізі.

Тож у підрозділі було описано модель та способи розрахунку ознак, що характеризують функціональні та структурні параметри серця на основі МРТзображень. Представлені підходи до розрахунків забезпечують об'єктивну оцінку ключових показників серцевої діяльності, що сприяє розв'язанню задач діагностики.

3.4. Основні кроки методу

У цьому розділі розглянуто основні кроки методу інтерпретації результатів, отриманих засобами ГН. Основна мета методу — представити ключові ознаки у формі, зручній для візуалізації та аналізу, забезпечуючи таким чином прозорість процесу класифікації патологій.

Вхідною інформацією методу є сегментоване (за методом багатоступеневої сегментації, представленого в підрозділі 2.1) МРТ-зображення та результат класифікації для нього.

Крок 1. Отримання значення ознак.

На першому кроці визначаються значення ознак за відповідними формулами (2.10)-(3.3) для патології *d* з вхідного зображення. Це забезпечує числову основу для подальшого аналізу.

Крок 2. Подання отриманих ознак.

На другому кроці ознаки подаються кінцевому користувачеві за типами *type*_i у вигляді, показаному на рис. 3.1.

Вихідною інформацією методу є вхідне сегментоване та класифіковане МРТзображення та візуалізовані за *type*_i ознаки.

Загальна схема методу інтерпретації отриманих результатів наведена на рис. 3.4.



Рис. 3.4 – Загальна схема методу інтерпретації.

Тож основні кроки методу інтерпретації отриманих рішень дозволяють підвищити доступність і зрозумілість отриманих даних для подальшого аналізу. Завдяки обчисленню ключових ознак та їхній візуалізації користувачі, включно з лікарями та дослідниками, отримують можливість оцінити результати класифікації. Це сприяє не лише більшій довірі до моделей ГН, але й їх ефективному використанню для діагностики пацієнтів із серцевими патологіями.

3.5. Висновки до розділу 3

У розділі розглянуто підхід до інтерпретації рішень, отриманих за моделями глибокого навчання, на основі медичних ознак, які використовуються лікарями для діагностики серцевих захворювань. Запропонована модель інтерпретації забезпечує перехід від «чорної скрині» штучного інтелекту до зрозумілого представлення результатів, включаючи числові показники, кругові діаграми та візуалізацію даних у 17-сегментній моделі міокарда.

Визначено основні групи медичних ознак, включаючи об'єми шлуночків, фракцію викиду, співвідношення об'ємів та маси, а також товщину і варіабельність стінок міокарда. Для кожної патології запропоновано специфічний набір ознак з рекомендованими способами подання. Розрахунок ознак ґрунтується на обробці сегментованих МРТ-зображень та враховує специфічні характеристики кожної групи патологій.

Описаний метод дозволяє стандартизувати аналіз МРТ-зображень та мінімізувати суб'єктивність у діагностиці. Завдяки запропонованій візуалізації результати стають більш інтуїтивно зрозумілими для лікарів, що сприяє підвищенню довіри до рішень, отриманих за допомогою моделей штучного інтелекту, та їх інтеграції в клінічну практику.

РОЗДІЛ 4.

ЕКСПЕРИМЕНТАЛЬНЕ ПІДТВЕРДЖЕННЯ ВАЛІДНОСТІ ЗАПРОПОНОВАНИХ МЕТОДІВ

4.1. Опис застосування

Розроблене програмне застосування є інструментом для валідації результатів сегментації та класифікації МРТ-зображень серця, а також інтерпретації отриманих результатів. Основний функціонал застосунку реалізовано через три взаємопов'язані методи:

1. Метод багатоступеневої сегментації МРТ-зображень, який виділяє анатомічні структури серця, необхідні для подальшого аналізу.

2. Метод каскадної класифікації патологій, що використовує результати сегментації для діагностики потенційних серцево-судинних захворювань.

3. Метод інтерпретації рішень моделей глибокого навчання, який генерує пояснювальні візуалізації та показує дані, що використовуються у медичній практиці і допомагають лікарям краще зрозуміти, на які дані система звертає увагу під час отримання результатів.

Застосування розроблене на основі клієнт-серверної архітектури. Такий підхід забезпечує розподіл обчислювальних завдань між серверною та клієнтською частинами, що сприяє ефективності, масштабованості та гнучкості системи. Тож система складається з двох основних компонентів:

1. Клієнтська частина, яка відповідає за взаємодію з користувачем. Клієнт забезпечує введення вихідних даних, відображення результатів аналізу та формування запитів до серверної частини. Реалізована на основі сучасних вебтехнологій, таких як Next.js і React, клієнтська частина підтримує інтерактивність та зручність інтерфейсу.

2. Серверна частина. Це обчислювальне ядро системи, яке виконує аналіз даних, обробляє запити від клієнта та повертає результати. Сервер реалізовано з

використанням FastAPI для створення REST API, що забезпечує високу продуктивність навіть за умов значного навантаження.

Основна взаємодія між клієнтською та серверною частинами організована через REST API, що дозволяє стандартизувати передачу даних та інтегрувати додаток із зовнішніми системами, якщо це необхідно.

Процес обробки даних у системі включає кілька етапів:

1. *Передача даних від клієнта*: користувач завантажує вихідні МРТзображення та супутні дані через інтерфейс клієнта. Дані передаються до серверної частини для обробки.

2. *Сегментація МРТ-зображень*: серверна частина передає дані до модуля сегментації, який виділяє ключові анатомічні структури серця.

3. *Класифікація патологій серця*: результати сегментації передаються до модуля класифікації, де виконується аналіз і виявлення можливих патологій.

4. *Інтерпретація рішень прийнятих*: модуль інтерпретації аналізує отримані результати класифікації за методами глибокого навчання, створюючи пояснювальні візуалізації та числові показники.

5. Повернення результатів клієнту: остаточні результати передаються клієнтській частині для відображення у вигляді, що використовується в медичній практиці.

Такий підхід дозволяє системі бути не тільки структурованою, а й масштабованою. Завдяки розподілу обов'язків, клієнтська частина зосереджується на користувацькому досвіді, тоді як сервер забезпечує централізовану обробку даних. Додатковою перевагою є гнучкість системи. Клієнт і сервер розробляються незалежно, що дозволяє використовувати різні технології для кожного з компонентів. Наприклад, клієнт може бути вебдодатком, графічним або ж консольним застосуванням, тоді як сервер працює у хмарному середовищі незалежно. Це дає змогу адаптувати систему до потреб конкретного проєкту та легко інтегрувати нові функції.

На рис. 4.1 зображено високорівневу схему послідовностей реалізованої програми, яка демонструє взаємодію між різними компонентами системи під час обробки МРТ-зображень.



Рис. 4.1 – Діаграма послідовності.

Серверна частина застосунку побудована з використанням сучасних бібліотек Python. Основу apxiteктури складає FastAPI, який забезпечує створення швидких і надійних REST API. Це дозволяє серверу отримувати запити від клієнтів, обробляти їх і повертати результати в зручному форматі, наприклад, у JSON.

На сервері обробка даних реалізована через інтеграцію бібліотек, таких як NumPy для роботи з числовими масивами, яка дозволяє швидко виконувати обчислення з великими даними; nibabel для зчитування MPT-зображень у форматі NIfTI, збереження і трансформацію цих даних.

Ключову роль у реалізації відіграють бібліотеки для машинного та глибокого навчання. Для цього використовується fastai та слугує основним інструментом для побудови, тренування та використання моделей глибокого навчання. Вона надає зручний інтерфейс для швидкої роботи з нейронними мережами, особливо в задачах класифікації чи сегментації зображень. У поєднанні з torchvision, яка підтримує

трансформацію зображень та використання попередньо тренованих моделей, серверна частина легко адаптується до широкого спектра задач.

Клієнтська реалізована частина додатка 3 використанням сучасних вебтехнологій, забезпечуючи інтерактивний і зручний користувацький досвід. Основою клієнтської частини € Next.is. який **ДОЗВОЛЯ** є створювати високопродуктивні серверно-рендерні і статично генеровані вебдодатки. Для візуалізації даних у додатку використовується Chart.js, який інтегрується з React через бібліотеки, такі як react-chartis-2. Chart.js забезпечує створення різних типів графіків і діаграм – лінійних, стовпчастих, кругових тощо. Це дозволяє відображати результати аналізу для користувача (рис. 4.2).



Рис. 4.2 – Інтерфейс звіту інтерпретації

Розроблене застосування забезпечує можливість валідації методів, описаних у дослідженні, а саме сегментації, класифікації та інтерпретації МРТ-зображень серця. Система базується на клієнт-серверній архітектурі, що дозволяє розподіляти обчислювальні задачі між компонентами. Поєднання описаних технологій

забезпечує інтерактивність, продуктивність і гнучкість клієнтської частини, дозволяючи легко адаптувати її до потреб користувачів і розширювати функціонал додатка.

4.2. Опис набору даних

У роботі використовується набір даних D_1 Automated Cardiac Diagnosis Challenge (ACDC) [23], структура якого описана в підрозділі 2.2.1. Набір складається зі 150 пацієнтів та містить 5 груп: 30 – здорових пацієнтів; 30 – пацієнтів з перенесеним раніше інфарктом міокарда; 30 – пацієнтів з дилатаційною кардіоміопатією; 30 – пацієнтів з гіпертрофічною кардіоміопатією; 30 – пацієнтів з аномалією правого шлуночка.

У наборі використовуються МРТ-зображення, отримані за допомогою послідовності SSFP (Steady-State Free Precession) та за допомогою двох сканерів з різною магнітною силою (1.5 T i 3.0 T). Ці зображення мають високу контрастність і роздільну здатність, що дозволяє точно оцінювати фізіологічні параметри серця. Якість кожного зображення дещо варіюється для різних пацієнтів через використання сканерів з різною магнітною силою . Загалом, якість всіх зображень висока та немає негативного впливу на якість навчання. Більше того, присутня варіативність сприяє ефективному навчанню моделей, оскільки забезпечує їх адаптивність до різних умов зображення. Це дозволяє покращувати генералізацію моделей, підвищуючи їхню здатність працювати на нових даних або в умовах, які відрізняються від вихідного набору.

Дані про кожного пацієнта включають фізичні параметри, набір зображень та розмічених експертами масок (ground truth label) на різних етапах серцевого циклу. Експертні маски містять розмічені сегменти для міокарда, лівого та правого шлуночків. Приклад елемента набору даних D_1 (2.1) зображений на рис. 4.3.



Рис. 4.3 – Зразок з набору даних D_1 : a – МРТ-зображенням серця; δ – маска

У поточній роботі за основу використовується оригінальний набір даних D_1 для коректного та більш наочного порівняння з іншими авторами. Для навчання та тестування моделей (M_1 - M_{10}) були створені відповідні модифікації наборів даних, структуру та кроки створення яких описано в підрозділі 2.2.1. Далі наведено приклади елементів набору даних та їх особливості.

Для навчання моделей локалізації (M_1 - M_3) створено набір даних D_2 (2.2) який містить 2978 МРТ-зображення. Всі зображення обрізані таким чином, що мають однакову роздільну здатність (256 рх × 256 рх) та співвідношення сторін (1:1). Для певного зображення була сформована окрема маска для кожної з досліджуваних структур серця (лівого і правого шлуночків та міокарда). Приклад елементу набору даних D_2 зображений на рис. 4.4.



в – маска сегмента правого шлуночка; г – маска сегмента лівого шлуночка

Для навчання моделей генерації масок (M_4 - M_6) було створено відповідні набори даних D_3 (2.3)(2.5), D_4 (2.6), D_5 (2.7), на основі набору даних D_2 , тому мають таку саму кількість зображень. Всі зображення з наборів даних мають однакову роздільну здатність (64 рх×64 рх) та співвідношення сторін (1:1). Кожен з наборів даних відповідає за окрему досліджувану структуру.

Набір даних *D*₃ містить локалізовані зображення лівого шлуночка та відповідну локалізовану маску. Приклад елемента набору даних *D*₃ зображений на рис. 4.5.



Рис. 4.5 – Приклад елемента набору даних D₃: *a* – MPT-зображення; *б* – маска сегмента лівого шлуночка.

Набір даних *D*₄ містить локалізовані зображення правого шлуночка та відповідну локалізовану маску. Приклад елемента набору даних *D*₄ зображений на рис. 4.6.



Рис. 4.6 – Приклад елемента набору даних *D*₄: *a* – МРТ-зображення; *б* – маска сегмента правого шлуночка

Набір даних D_5 містить локалізовані зображення міокарда та відповідну локалізовану маску. Приклад елемента набору даних D_5 показаний на рис. 4.7.



Рис. 4.7 – Приклад елемента набору даних *D*₅: *a* – МРТ-зображення; *б* – маска сегмента міокарда

Для навчання каскаду моделей класифікації (M_7 - M_{10}) було сформовано набір даних D_6 (2.17), структура та кроки створення якого описана в підрозділі 2.2.1. Набір даних містить модифіковані МРТ-зображення для пацієнта та класи з відповідних патологій. Модифікація МРТ-зображень полягає в тому, що кожен сегмент серця (міокард, лівий і правий шлуночки) розміщується в окремих каналах кольорової моделі RGB.

Всі зображення обрізані відповідно до найбільшої зони локалізації з набору даних одного пацієнта та мають однакову роздільну здатність (64 рх×64 рх) та співвідношення сторін (1:1). Весь набір даних містить, як і оригінальний набір даних, 150 пацієнтів, які поділені на 5 груп. Приклад елемента набору даних D_3 наведений на рис. 4.8.



Рис. 4.8 – Приклад елемента набору даних *D*₆: набір модифікованих МРТ-зображень
Таким чином, було сформовано 5 нових наборів даних D_{2-6} , які використовуються для локалізації області інтересів та визначення точних контурів на МРТ-зображеннях, а також для класифікації МРТ-зображень за класами патологій.

4.3. Опис експериментів за методом багатоступеневої сегментації МРТзображень

Для валідації запропонованого у роботі методу багатоступеневої сегментації (підрозділ 2.1), пропонується провести порівняння результатів з роботами інших авторів, а саме порівняння точності сегментації окремих структур серця за коефіцієнтом Дайса (1.1). Також для підтвердження позитивного впливу запропонованих кроків методу на кінцевий результат сегментації, пропонується провести ряд експериментів, поступово збільшуючи складність навчання моделі і додаючи окремі кроки або їх комбінації. Були проведені такі експерименти:

1) сегментація оригінальних МРТ-зображень — для визначення базової здатності моделі глибокого навчання розпізнавати серцеві структури;

2) сегментація локалізованого МРТ-зображення за оригінальною маскою – для оцінки впливу попередньої локалізації на кінцевий результат сегментації;

3) сегментація оригінальних зображень за декомпозованими масками – для оцінки використання бінарної сегментації замість мультиструктурної;

 4) сегментація локалізованого МРТ-зображення за декомпозованими масками
 для оцінки застосування комбінації попередньої локалізації та використання бінарної сегментації замість мультиструктурної;

5) сегментація локалізованого МРТ-зображення за декомпозованими масками з використанням постобробки (запропонований підхід) – для оцінки комбінації всіх кроків запропонованого методу.

Мета цих експериментів – визначити внесок кожного кроку в підвищення точності сегментації, зокрема щодо складних областей, таких як міокард і правий шлуночок.

Авторами набору даних ACDC [23] сформовано окремо навчальний та тестовий набори даних на 100 та 50 пацієнтів, відповідно. Використання попередньо сформованих наборів замість власного розбиття дозволяє більш коректно порівнювати результати експериментів з роботами інших авторів завдяки використанню однакового тестового набору даних. Тож для всіх експериментів у розділі використовується саме попередньо сформований авторами набору тестовий набір даних.

4.3.1. Сегментація оригінальних МРТ-зображень

На першому етапі експериментів була навчена базова модель ГН (M_1^{exp1}) для сегментації МРТ-зображень без попередньої локалізації чи декомпозиції. Модель приймала вхідні зображення без попереднього виділення області інтересу чи розділення анатомічних структур на окремі класи для аналізу. Її основною метою було виявлення контурів міокарда, а також лівого і правого шлуночків на всьому зображенні. Такий підхід оцінював базову здатність моделі розпізнавати серцеві структури без використання додаткових методів обробки, що ускладнювалося наявністю фонових даних, шумів і наявністю інших органів на зображенні. Цей експериментальний етап слугував базовою оцінкою точності методу та його потенціалу для подальшого вдосконалення.

Для кожного зразка тестового набору обраховувався коефіцієнт Дайса за (1.1). У кінці було обчислено його середнє значення для різних сегментів серця окремо. Загальна точність сегментації за (2.12) склала 0.860.

Отримані результати сегментації наведено для кінцевих діастоли і систоли (таблиця 4.1).

Результати експерименту 1.

Отримані середні значення коефіцієнта Дайса для різних сегментів.

Кінцева діастола				Кінцева систола			
Модель	Лівий	Правий	Міокард	Лівий	Правий	Міокард	
	шлуночок	шлуночок	ЛШ	шлуночок	шлуночок	ЛШ	
M_1^{exp1}	0.890	0.871	0.832	0.911	0.842	0.812	

Результати цього експерименту показані на рис. 4.9.



Рис. 4.9 – Порівняння масок для оригінальних зображень: *а* – експертна маска; *б* – маска, отримана нейронною мережею

Отримані результати свідчать, що базова модель (M_1^{exp1}) демонструє нижчий рівень точності порівняно з іншими авторами [136-139], проте є достатнім для базового сценарію, враховуючи відсутність будь-яких додаткових етапів покращення, таких як попередня локалізація або декомпозиція зображення. Найкращі показники досягнуті для лівого шлуночка (коефіцієнт Дайса = 0.911 у діастолі та 0.89 – у систолі), що підтверджує здатність моделі до розпізнавання чітких структур. Водночас сегментація міокарда (коефіцієнт Дайса = 0.812 та 0.832) залишається більш складним завданням, що вказує на можливості для подальшого вдосконалення.

4.3.2. Сегментація локалізованого МРТ-зображення за оригінальною маскою

На другому етапі експериментів було застосовано комбінований підхід, який поєднував локалізацію області серця та подальшу мультиструктурну сегментацію. Спершу попередньо навчена модель глибокого навчання $(M_1^{exp^2})$ виконувала локалізацію серцевої області, що включала міокард лівого шлуночка та правий і лівий шлуночки одночасно. Це дозволило звузити область інтересу, усунувши вплив фонових структур, таких як кісткова тканина, легені або інші органи, які не є релевантними для аналізу серця.

Локалізоване зображення передавалося на вхід моделі глибокого навчання для сегментації ($M_2^{exp^2}$). Завдяки такому підходу стратегії модель могла фокусуватися виключно на ключових серцевих структурах, що зменшувало кількість помилкових результатів і дозволяло покращити точність визначення контурів. Також зменшувалася обчислювальна складність завдяки меншому обсягу оброблюваних даних. Метою цього етапу було оцінити, наскільки ефективною є попередня локалізація для покращення сегментації в умовах низької якості зображень або складних анатомічних випадків.

Отримані результати сегментації наведено окремо для кінцевої діастоли та кінцевої систоли (таблиця 4.2).

Таблиця 4.2

	Кін	нцева діасто	эла	Кінцева систола		
Модель	Лівий	Правий	Міокард	Лівий	Правий	Міокард
	шлуночок	шлуночок	ЛШ	шлуночок	шлуночок	ЛШ
M_1^{exp1}	0.911	0.842	0.812	0.890	0.871	0.832
$M_1^{exp2}M_2^{exp2}$	0.920	0.902	0.875	0.894	0.891	0.884

Результати другого експерименту.

Отримані	середні	значення	коефіцієнта	Дайса	для	різних	сегментів
1	1 1		1 7	r n	· · .	1	

Приклад результату описаного експерименту показаний на рис. 4.10, де *а* – експертна маска; *б* – маска, отримана нейронною мережею.



Рис. 4.10 – Порівняння масок для локалізованих зображень

Завдяки звуженню області інтересу моделі вдалося зосередитися на ключових структурах серця, що сприяло підвищенню точності. Для всіх структур загальна точність сегментації за (2.12) стала вищою та дорівнює 0.894, що на 3.88 % відносно базової моделі M_1^{exp1} . Найбільшу різницю можна спостерігати для точності сегментації правого шлуночка, коефіцієнт Дайса для якого зріс з 0.842 до 0.902 (+0.060) у діастолі та з 0.871 до 0.891 (+0.063) – у систолі. Решта показників як для міокарда, так і лівого шлуночка також покращилися. Тож попередня локалізація показала свою ефективність та довела доцільність у використанні.

4.3.3. Сегментація оригінальних зображень за декомпозованими масками

На третьому етапі експериментів було застосовано підхід сегментації з попередньою декомпозицією оригінальних МРТ-зображень. Оригінальні маски розділялися на окремі бінарні маски для кожної анатомічної структури (міокарда, лівого та правого шлуночків), що дозволило уникнути плутанини між структурами, характерної для багатоканальної сегментації. Кожна бінарна маска оброблялася окремою моделлю (M_1^{exp3} – для лівого шлуночка, M_2^{exp3} – для правого шлуночка,

M^{*exp*³} – для міокарда лівого шлуночка, що забезпечило деталізований аналіз форми
та текстури окремих структур. Основна мета цього підходу полягала в перевірці, чи
підвищує використання бінарних масок точність сегментації шляхом спрощення
завдання.

Отримані результати сегментації наведено окремо для кінцевої діастоли та кінцевої систоли (таблиця 4.3).

Таблиця 4.3

	Кінцева діастола				Кінцева систола			
Модель	Лівий	Правий	Міокард	Лівий	Правий	Міокард		
	шлуночок	шлуночок	ЛШ	шлуночок	шлуночок	ЛШ		
M_1^{exp1}	0.911	0.842	0.812	0.890	0.871	0.832		
$M_1^{exp3},$ $M_2^{exp3},$ M_3^{exp3}	0.919	0.892	0.855	0.887	0.873	0.885		

Результати третього експерименту.

Отримані середні значення коефіцієнта Дайса для різних сегментів.

Приклад результату цього експерименту показаний на рис. 4.11, де *а* – експертна маска; *б* – маска, отримана нейронною мережею; *в* – різниця між масками.



Рис. 4.11 – Порівняння масок для зображень в оригінальному розмірі з декомпозованими масками

Результати показали покращення точності сегментації міокарда з 0.812 до 0.855 (+0.043) для діастоли та з 0.832 до 0.885 (+0.053) завдяки зменшенню плутанини з іншими структурами. Проте, для лівого шлуночка покращення було менш вираженим для діастоли, з 0.911 до 0.919 (+0.008), та навіть продемонструвало погіршення для систоли (точність знизилася з 0.890 до 0.889 (-0.003)), оскільки слабкий контраст із сусідніми тканинами та вплив фонових структур залишався проблемою. Загальна точність сегментації для всіх структур за (2.12) дорівнює 0.885, тож збільшилася на 2.88 % порівняно з базовою моделлю M_1^{exp1} . Загалом, декомпозиція підтвердила свою ефективність для складних випадків, однак її застосування без етапу локалізації виявило обмеження, особливо для шлуночків.

4.3.4. Сегментація локалізованого МРТ-зображення за декомпозованими масками

Четвертий етап експериментів реалізував інтеграцію двох підходів — локалізації та декомпозиції. Для експерименту використовувалися моделі, запропоновані в підрозділі 2.1.1 (*M*₁, *M*₂, *M*₃, *M*₄, *M*₅, *M*₆), доповнені кроком постобробки.

У цьому експерименті, на відмінну від $M_1^{exp^2}$, моделі локалізації навчалися окремо для кожної анатомічної структури. На кроці 1 було визначено область розташування лівого і правого шлуночків та міокарда з використанням моделей M_1 , – для лівого шлуночка, M_2 , – для правого шлуночка та M_3 – для міокарда лівого шлуночка, що, у свою чергу, сприяло зменшенню плутанини з різними структурами.

Після цього на кроці 2 було проведено генерацію масок лівого і правого шлуночків та міокарда з використанням моделей M_4 – для лівого шлуночка, M_5 – для правого шлуночка та M_6 – для міокарда лівого шлуночка, за аналогією з експериментом 3.

На кроці 3 було проведено постобробку отриманих масок, а саме: згладжування масок за (2.9), комбінування 3-х окремих масок в одну загальну за допомогою (2.10) та зіставлення комбінованої маски, відповідно до розміру вхідного зображення, за допомогою (2.11).

Основна мета цього експерименту полягала в перевірці того, як впливає комбінування локалізації та декомпозиції масок на точність сегментації.

Отримані результати сегментації наведено окремо для кінцевої діастоли та кінцевої систоли (таблиця 4.4).

Таблиця 4.4

Кінцева діастола				Кінцева систола			
Модель	Лівий	Правий	Mioropy IIII	Лівий	Правий	Міокард	
	шлуночок	шлуночок	мпокард лш	шлуночок	шлуночок	ЛШ	
M_1^{exp1}	0.911	0.842	0.812	0.890	0.871	0.832	
$M_1, M_2, M_3,$	0.956	0 939	0.866	0 930	0 905	0.898	
M_4, M_5, M_6	0.750	0.757	0.000	0.750	0.705	0.070	

Результати четвертого експерименту.

Отримані середні значення коефіцієнта Дайса для різних сегментів.

Приклад результату описаного експерименту показаний на рис. 4.12, де *а* – експертна маска; *б* – маска, отримана нейронною мережею; *в* – різниця між масками.



Рис. 4.12 – Порівняння масок для локалізованих зображень з декомпозованими масками

Результати четвертого етапу експериментів демонструють, що інтеграція локалізації та декомпозиції суттєво підвищує точність сегментації серцевих структур порівняно з базовою моделлю. Для всіх структур загальна точність сегментації за (2.12) була покращена до 0.916, що на 6.12 %, порівнюючи з базовою моделлю M_1^{exp1} . Це покращення можна пояснити використанням окремих моделей для локалізації та сегментації кожної анатомічної структури, що дозволило уникнути плутанини між різними сегментами і зменшити вплив фонових артефактів. Окрема локалізація забезпечила більш точне визначення меж області інтересу, тоді як декомпозиція дозволила моделям сфокусуватися на деталях кожної структури.

4.3.5. Сегментація локалізованого МРТ-зображення за декомпозованими масками з використанням постобробки (запропонований підхід)

На п'ятому – завершальному етапі експериментів – було застосовано усі попередні етапи, тож була реалізована повна схема запропонованого методу, яка поєднувала локалізацію і генерацію масок за декомпозованими масками та постобробку контурів маски.

Локалізація та генерація масок відбувалася аналогічно до попереднього експерименту, тож використовувалися моделі, запропоновані в підрозділі 3.1.1 (M_1 , M_2 , M_3 , M_4 , M_5 , M_6).

На відміну від попередніх експериментів, після отримання результатів сегментації, виконувалася постобробка, спрямована на покращення якості сегментованих масок. Цей етап включав згладжування контурів для усунення артефактів, які могли виникнути через невелику помилкову розмітку або шум у даних. Постобробка також передбачала використання методів розмиття для зменшення жорстких переходів між різними областями та створення більш природного вигляду контурів сегментованих структур. Крім того, маски були повернуті до початкового розміру, що забезпечувало коректність порівняння результатів з експертними масками.

Застосування постобробки дозволило усунути залишкові артефакти, які могли б знизити якість сегментації, особливо для правого шлуночка, де часто спостерігаються слабкий контраст і перекриття із сусідніми тканинами. Маски, отримані після цього етапу, демонстрували вищу відповідність експертним масками.

Отримані результати для завершального етапу експериментів наведено окремо для кінцевої діастоли та кінцевої систоли (таблиця 4.5).

Таблиця 4.5

	Кін	нцева діаст	ола	Кінцева систола		
Модель	Лівий	Правий	Міокард	Лівий	Правий	Міокард
	шлуночок	шлуночок	ЛШ	шлуночок	шлуночок	ЛШ
M_1^{exp1}	0.911	0.842	0.812	0.890	0.871	0.832
$M_1, M_2, M_3,$						
M_4, M_5, M_6	0.974	0.947	0.896	0.940	0.915	0.920
+ постобробка						

Результати п'ятого експерименту.

Отримані середні значення коефіцієнта Дайса для різних сегментів.

Результати експерименту 5 показано на рис. 4.13, де *a* – експертна маска; *б* – маска, отримана нейронною мережею; *в* – різниця між масками.



Рис. 4.13 – Порівняння масок для локалізованих зображень з декомпозованими масками та підсиленням контурів

Запропонований підхід показав найкращі результати серед усіх етапів експериментів. Він забезпечив максимальну точність сегментації для всіх досліджуваних структур, особливо для лівого шлуночка та міокарда, які мають вирішальне значення для медичного аналізу. Таким чином, комбінація локалізації, декомпозиції та постобробки підтвердила свою ефективність як цілісна стратегія для автоматизованої сегментації серцевих структур на МРТ-зображеннях

Порівняння всіх результатів експериментів, отриманих для визначення ефективності етапів локалізації, декомпозиції та постобробки, наведені у таблиця 4.6).

Таблиця 4.6

Обчислювальні результати, тобто значення коефіцієнта Дайса, для перевірки ефективності етапів локалізації, декомпозиції та постобробки ...

	Кінцева діастола			Кінцева систола		
Експеримент	Лівий	Правий	Міокард	Лівий	Правий	Міокард
	шлуночок	шлуночок	ЛШ	шлуночок	шлуночок	ЛШ
Експеримент 1	0.911	0.842	0.812	0.890	0.871	0.832
Експеримент 2	0.920	0.902	0.875	0.894	0.891	0.884
Експеримент 3	0.919	0.892	0.855	0.887	0.873	0.885
Експеримент 4	0.956	0.939	0.866	0.930	0.905	0.898
Експеримент 5						
(запропонований	0.974	0.947	0.896	0.940	0.915	0.920
підхід)						

в рамках запропонованого методу сегментації.

Аналіз Таблиця 4.6 демонструє зростання точності сегментації за коефіцієнтом Дайса для кожного наступного експерименту, починаючи від базової моделі.

Візуальне порівняння всіх результати експериментів у вигляді горизонтальної стовпчикової діаграми зображено на рис. 4.14.



Рис. 4.14 – Візуальне порівняння отриманих значень коефіцієнта Дайса для експериментів 1–5 (ES – кінцева систола, ED – кінцева діастола)

Таким чином, результати експериментів продемонстрували підвищення точності сегментації за запропонованим методом, який включає локалізацію, декомпозицію та постобробку зображень. Загальна точність сегментації для всіх структур за (2.12) зросла до 0.932, що на 7.7 6% більше порівняно з базовою моделлю M_1^{exp1} . Отже, запропонований підхід забезпечує високу точність сегментації структур серця на МРТ-зображеннях, що є критично важливим для подальшого клінічного аналізу та діагностики.

4.3.6. Порівняння запропонованого підходу з сучасними методами сегментації

Отримані результати сегментації були порівняні із сучасними методами, описаними в огляді літературі, оремо для кожної структури за коефіцієнтом Дайса для кінцевих фаз діастоли та систоли (таблиця 4.7).

Для лівого шлуночка запропонований метод досяг найвищих значень коефіцієнта Дайса: 0.974 – у фазі кінцевої діастоли та 0.940 – у фазі кінцевої систоли. Порівняно з методом Hu et al. [136], який є найближчим конкурентом, запропонований метод показує кращі результати, що свідчить про здатність запропонованого підходу забезпечувати більш точне відокремлення контурів.

Сегментація правого шлуночка, яка традиційно вважається складним завданням через слабкий контраст із сусідніми тканинами, також демонструє переваги запропонованого методу. У фазі кінцевої діастоли коефіцієнт Дайса становив 0.947, що є найкращим серед усіх порівнюваних методів, перевищуючи найближчі результати Hu et al. [136]. У фазі кінцевої систоли точність також залишається найвищою серед конкурентних підходів.

Щодо сегментації міокарда лівого шлуночка, запропонований метод показав значне покращення. У фазі кінцевої діастоли коефіцієнт Дайса досягнув 0.896, що є меншим показником ніж найближчі результати Hu et al. [136], проте краще за результати інших конкурентів, зокрема Sander et al. [137], де цей показник становив лише 0.875. У фазі кінцевої систоли запропонований підхід досяг найвищого значення серед усіх порівнюваних робіт — 0.920, що незначним чином перевершує найближчий результат Hu et al. [136].

Таким чином, загальна точність сегментації для всіх структур за (2.12) для запропонованого методу багатоступеневої сегментації дорівнює 0.932, що на 2.08 % більше за результати авторів [138], для яких цей показник дорівнює 0.913; на 2.41 % більше за результати авторів [137], для яких цей показник дорівнює 0.910; на 2.08 % більше за результати авторів [139], для яких цей показник дорівнює 0.913; на 0.54 % більше за результати авторів [136], для яких цей показник дорівнює 0.927.

Показники всіх згаданих авторів представлені в таблиця 4.7 порівняно з результатами запропонованого методу.

Таблиця 4.7

122

	Кін	цева діастол	18	Кінцева систола			
Робота	Лівий	Правий	Міокард	Лівий	Правий	Міокард	
	шлуночок	шлуночок	ЛШ	шлуночок	шлуночок	ЛШ	
Запропонований	0.974	0.947	0.896	0.940	0.915	0.920	
метод			0.070		01710	0.720	
Hu et al. [136]	0.968	0.946	0.902	0.931	0.899	0.919	
Silva et al. [139]	0.963	0.932	0.892	0.911	0.883	0.901	
Jang et al. [137]	0.959	0.929	0.875	0.921	0.885	0.895	
Ammar et al. [138]	0.964	0.935	0.889	0.917	0.879	0.898	

Порівняння результатів сегментації із сучасними методами за коефіцієнтом Дайса.

Візуальне порівняння всіх результатів експериментів у вигляді горизонтальної стовпчикової діаграми показано на рис. 4.15.



Рис. 4.15 – Візуальне порівняння отриманих значень коефіцієнта Дайса з роботами інших авторів (ES – кінцева систола, ED – кінцева діастола).

Отримані результати свідчать про те, що запропонований метод перевершує більшість сучасних підходів за точністю сегментації лівого і правого шлуночків та міокарда. Особливо значне покращення спостерігається у випадку правого шлуночка, що свідчить про ефективність використання локалізації, декомпозиції та постобробки. Метод демонструє стабільність і високу точність у всіх фазах серцевого циклу, що робить його перспективним для застосування у клінічній практиці.

4.3.7. Валідація експертних масок та отриманих результатів медичним спеціалістом

Під час навчання та тестування запропонованих моделей на оригінальному наборі даних було виявлено певні неточності у масках. Навіть незначні розбіжності між масками у процесі навчання і тестування можуть суттєво впливати на точність оцінювання результатів. Ці неточності включають як помилкове позначення частин зображення, так і пропущені області сегментів. Наприклад, на рис. 4.16 (a – маска, розмічена експертом; δ – маска, отримана запропонованим методом; e – різниця між масками) видно, що у верхній частині лівого шлуночка позначена «зайва» область, яка в оригінальному наборі даних експертами хибно відмічена як частина міокарда (зона 1 на рис. 4.16), але запропонований метод правильно розпізнав та відділив цю частину лівого шлуночка від тканини міокарда. Таким самим чином можна спостерігати іншу ситуацію у правій частині міокарда. Запропонована модель правильно виявила область, яка в оригінальному наборі даних хибно не була позначена як м'язова тканина (зона 2 на рис. 4.16).



Рис. 4.16 – Порівняння масок експертної маски та маски згенерованою запропонованою моделлю

Отже, на основі детального аналізу отриманих масок, які показували нижчі показники точності порівняно з рештою тестової вибірки (менше 95 % збігу експертної та отриманої масок) виникло припущення, що в деяких випадках точність запропонованої моделі нижча не через хибні результати, а навпаки, завдяки більш точним результатам моделі ГН, які відрізняються від експертних, тож через свою відмінність знижують кінцеву оцінку. Таким чином, виникла потреба в залученні медичного спеціаліста для додаткової валідації тестового та навчального наборів даних і загалом всіх отриманих результатів.

Оскільки є потреба проаналізувати якість всіх зображень як тестової, так і навчальної вибірок, було сформовано згенеровану маску для кожного зображення в наборі даних, яка використовувалася для порівняння. Для гарантування відсутності маски в тестовій і навчальних вибірках одночасно було сформовано три набори даних для навчання та тестування, де оригінальний тестовий і навчальний набір даних було об'єднано в один загальний набір даних та перемішано випадковим чином. Тож загальна структура наборів залишилася такою самою, змінилося лише співвідношення та розподіл зображень. Нові експериментальні набори даних для навчання було розбито у співвідношенні 70/30, відповідно. Це дозволило сформувати окрему маску для кожного зображення, що дало можливість порівняти всі маски набору даних.

Для валідації отриманих результатів було залучено практикуючого кардіолога та розроблено спеціальний програмний застосунок для порівняння експертних масок і масок згенерованих запропонованою моделлю. Розроблений застосунок спеціально призначений для зручного застосування медичним спеціалістом та містить необхідні інструменти для детального порівняння двох масок, а саме: можливість корегувати основні показники зображення, такі як контрастність (міра виявлення (і, отже, розпізнавання) об'єкта на певному тлі) та яскравість (характеристика візуального кольоросприйняття зображення). Також було додано можливість корегування прозорості маски, що накладається, для покращення можливості оцінки точності її контурів. Медичний спеціаліст має можливість аналізувати зображення та маски в їхньому оригінальному розмірі, або збільшену локалізовану область, а також переглядати основну інформацію щодо пацієнтів і їхніх діагнозів, яка міститься в оригінальному наборі даних. Для уникнення заангажованості та упередженості спеціаліста, маски мали анонімізоване позначення (А, В). Задача медичного спеціаліста полягала у тому, щоб зробити вибір між запропонованими варіантами, а саме обрати одну з чотирьох варіантів оцінки маски: маска А має більшу точність, маска В має більшу точність, варіанти А та В мають однаково хороші маски (різниця між масками незначна та не має суттєвого впливу на результати медичних висновків), або варіанти А та В мають однаково погані маски.

Інтерфейс розробленого застосунку для проведення аналізу отриманих результатів сегментації медичним спеціалістом показано на рис. 4.17.



Рис. 4.17 – Інтерфейс застосунку для валідації отриманих масок.

У результаті аналізу спеціалістом було позначено, що 133 маски міокарда, 136 масок лівого шлуночка та 122 маски правого шлуночка було визначено більш точно за допомогою запропонованого методу, 56 масок міокарда, 52 маски лівого шлуночка та 30 масок правого шлуночка визначено з меншою точністю, 1976 масок міокарда, 1962 маски лівого шлуночка та 1959 масок правого шлуночка не мали значної різниці, що має суттєвий вплив на результати медичних висновків, та лише 1 маска міокарда, 2 маски лівого шлуночка та 5 масок правого шлуночка були однаково погано розмічені експертами та запропонованим методом (через погану якість вхідного зображення та погану візуалізацію серця і його частин).

Таблиця 4.8, таблиця 4.9 та таблиця 4.10 показують результати аналізу медичного спеціаліста масок міокарда, лівого і правого шлуночків, відповідно.

Результати аналізу медичного спеціаліста для масок міокарда.

Опис	Кількість відмічених зразків
Маска, отримана запропонованим методом, має	133
більшу точність	155
Маска, розмічена експертом, має більшу точність	56
Обидві маски мають високу точність і різниця	1976
між ними не суттєва	1970
Обидві маски мають низьку точність, недостатню	1
для отримання медичних висновків	1

Таблиця 4.9

Результати аналізу медичного спеціаліста для масок лівого шлуночка.

Опис	Кількість відмічених зразків
Маска, отримана запропонованим, методом має	136
більшу точність	150
Маска, розмічена експертом, має більшу	52
точність	
Обидві маски мають високу точність і різниця	1962
між ними не суттєва	
Обидві маски мають низьку точність,	2
недостатню для отримання медичних висновків	~

128

Опис	Кількість відмічених зразків
Маска, отримана запропонованим, методом має	122
більшу точність	122
Маска, розмічена експертом, має більшу	30
точність	
Обидві маски мають високу точність і різниця	1959
між ними не суттєва	
Обидві маски мають низьку точність,	5
недостатню для отримання медичних висновків	

Результати аналізу медичного спеціаліста для масок правого шлуночка.

Сумарна кількість масок у кожному наборі відрізняється (міокарда, лівого і правого шлуночків), оскільки не всі частини серця візуалізуються на всіх МРТзображеннях. Наприклад, правий шлуночок часто відображається на меншій кількості зрізів МРТ-зображення порівняно з лівим шлуночком.

Проведений аналіз показав, що запропонований метод сегментації демонструє високу точність у більшості випадків. Зокрема, 97.73 % масок мають задовільну та достатню якість для аналізу медичним спеціалістом, що підтверджує ефективність методу. Решта 2.27 % масок показали гірші результати, переважно через низьку якість вхідного зображення. До основних причин погіршення якості належать: низька роздільна здатність, артефакти зображення (наприклад, розмиття через рух пацієнта під час МРТ), а також низька яскравість або контрастність, спричинені технічними особливостями МРТ-апарату чи складнощами під час дослідження конкретного пацієнта.

Залучення медичного спеціаліста та розробка спеціального програмного застосунку для валідації дозволили детально оцінити результати сегментації. У 133 випадках маски міокарда, 136 випадках маски лівого шлуночка та 122 випадках маски правого шлуночка запропонований метод показав вищу точність порівняно з експертними масками. Водночас, 1976 масок міокарда, 1962 маски лівого шлуночка та 1959 масок правого шлуночка не мали суттєвих розбіжностей, а лише кілька масок, 1 – для міокарда, 2 – для лівого шлуночка та 5 – для правого шлуночка, виявилися однаково низької якості.

Таким чином, отримані результати підтверджують, що метод сегментації придатний для практичного використання, але у випадках низької якості вхідних зображень необхідне залучення експертів для уточнення та валідації результатів.

4.3.8. Аналіз функції втрат навчання та валідації для моделей сегментації

У цьому підрозділі буде проведено аналіз функції втрат навчання та валідації для всіх моделей сегментації. Навчання відбувалося в два етапи відповідно до опису стратегі навчання в підрозділі 2.1.4. Далі продемонстровані графіки, що візуалізують результати двох послідовних етапів навчання моделі з різною швидкістю навчання, у яких відстежувалися втрати на тренувальній та валідаційній вибірках. Для всіх моделей локалізації (M_1, M_2, M_3) та генерації масок (M_4, M_5, M_6) параметри навчання були однаковими і наведені в таблицях нижче.

Таблиця 4.11 демонструє параметри навчання для моделей локалізації.

Таблиця 4.11

Результати аналізу медичного спеціаліста для масок правого шлуночка.

Назва параметра	Значення
Максимальна кількість епох	100
Розмір пакета (batch size)	16
Розмір зображення	256
Архітектура	ResNet-50
Швидкість навчання першого етапу	1e-2
Швидкість навчання другого етапу	1e-7

На рис. 4.18 зображено графік, що демонструє динаміку втрат під час тренування та валідації моделі локалізації лівого шлуночка (*M*₁).



Рис. 4.18 – Порівняння тренувальних втрат проти валідаційних втрат для моделі локалізації ЛШ.

Аналіз графіка показує, що перший етап складався з невеликої кількості епох через застосування ранньої зупинки, яка відбулася після 5-ї епохи через невеликий скачок втрат валідації. Така динаміка може свідчити про початок потенційного перенавчання, тому варто зупиняти навчання на високій швидкості та переходити до більш повільного навчання. Друга ітерація мала значно більше епох через зміну параметрів навчання, зокрема зниження швидкості навчання, яке відбувалося повільно, водночас втрати валідації та втрати навчання знижуються стабільно, що свідчить про поступове навчання на узагальнення. Тож така динаміка демонструє, що навчання відбувається ефективно.

На рис. 4.19 зображено графік, що демонструє динаміку втрат під час тренування та валідації моделі локалізації правого шлуночка (*M*₂).



Рис. 4.19 – Порівняння тренувальних втрат проти валідаційних втрат для моделі локалізації ПШ

У випадку моделі локалізації правого шлуночка навчання мало схожу з попереднім випадком структуру, але валідаційні втрати мали подібні коливання на перших етапах. Рання зупинка першого етапу відбулася доволі швидко, але пізніше ніж для попередньої моделі, після 8-ї епохи, але тут подальше навчання йшло більш плавно. Втрати валідації протягом другої ітерації залишалися стабільними, що може свідчити про коректне налаштування швидкості навчання і покращену генералізацію.

На рис. 4.20 зображено графік, що демонструє динаміку втрат під час тренування та валідації моделі локалізації міокарда лівого шлуночка (*M*₃).



Рис. 4.20 – Порівняння тренувальних втрат проти валідаційних втрат для моделі локалізації МЛШ

Для моделі локалізації міокарда лівого шлуночка графік відображає схожу тенденцію, проте тут можна помітити, що початкове зростання валідаційних втрат відбулося менш різко. Це може свідчити про те, що модель була менш чутливою до зміни параметрів у перших епохах. Швидкість навчання змінилася після 9-ї епохи. Друга ітерація навчання показала більш стабільне зниження втрат, яке на графіку виглядає малопомітним, що може свідчити про те, що для цього випадку швидкість навчання могла б бути дещо нижчою. Проте все одно навчання відбувалося, динаміка втрат хоч і повільна, але стабільна.

Моделі локалізації продемонстрували схожі тенденції під час навчання: початковий етап завершувався через ранню зупинку, що запобігало перенавчанню, після чого модель продовжувала вдосконалюватися зі зменшеною швидкістю навчання. У всіх випадках вдалося досягти стабільного зниження тренувальних і валідаційних втрат, що свідчить про ефективне узагальнення. Незначні коливання втрат на перших етапах можуть бути спричинені особливостями обробки даних, але загалом навчання проходило передбачувано і ефективно.

Таблиця 4.12 демонструє параметри навчання для моделей генерації масок.

Таблиця 4.12

Результати аналізу медичного спеціаліста для масок правого шлуночка.

Назва параметра	Значення
Максимальна кількість епох	100
Розмір пакета (batch size)	32
Розмір зображення	64
Архітектура	ResNet-34
Швидкість навчання першого етапу	1e-2
Швидкість навчання другого етапу	1e-7

На рис. 4.21 зображено графік, що демонструє динаміку втрат під час тренування та валідації моделі генерації масок лівого шлуночка (*M*₄).



Рис. 4.21 – Порівняння тренувальних втрат проти валідаційних втрат для моделі генерації масок ЛШ

На відміну від попередніх випадків, модель генерації масок лівого шлуночка продемонструвала більш виразні коливання валідаційних втрат на початковому

етапі, а динаміка зниження втрат більш помітна ніж в інших моделях. Це може бути ознакою швидкого запам'ятовування тренувальних даних. Втрати навчання спочатку теж знижувалися різко, але пізніше стабілізувалися та продовжили стабільне зниження після зміни швидкості навчання після 5-ї епохи. Це свідчить про гарне узагальнення.

На рис. 4.28 зображено графік, що демонструє динаміку втрат під час тренування та валідації моделі генерації масок правого шлуночка (*M*₅).



Рис. 4.22 – Порівняння тренувальних втрат проти валідаційних втрат для моделі генерації масок ПШ

У випадку моделі генерації масок правого шлуночка динаміка втрат була подібною, але тут спостерігалося дещо повільне зниження втрат у другій фазі. Це може бути пов'язано з особливостями розподілу даних або складністю самої задачі. Незважаючи на це, кінцева стабільність показників свідчить про те, що модель добре адаптувалася до навчального процесу, і валідаційні втрати не демонстрували ознак різкого зростання після певної кількості епох. Швидкість навчання була автоматично змінена після 7-ї епохи.

На рис. 4.23 зображено графік, що демонструє динаміку втрат під час тренування та валідації моделі генерації масок міокарда лівого шлуночка (M_6).

Остання модель (модель генерації масок міокарда лівого шлуночка) показала найбільш рівномірний хід навчання. Вона мала типовий спад втрат у першій фазі та стабілізацію після зміни параметрів у другій. Швидкість навчання була змінена протягом 8-ї епохи після ледь помітного збільшення втрат валідації. На відміну від

інших моделей, тут не було вираженого коливання валідаційних втрат, що свідчить про більш передбачувану поведінку під час тренування.



Рис. 4.23 – Порівняння тренувальних втрат проти валідаційних втрат для моделі генерації масок МЛШ

Моделі генерації масок мали стабільну динаміку зниження втрат, особливо на другому етапі, що може свідчити про якісне засвоєння основних закономірностей у тренувальних даних. У другій фазі навчання тренувальні втрати продовжували поступово зменшуватися, тоді як валідаційні втрати стабілізувалися, що вказує на хорошу генералізацію.

Загалом аналіз графіка втрат для всіх моделей демонструє два основні тренди. Протягом першої ітерації відбувалося швидке зменшення втрат, що є типовим для початкових етапів навчання з високою швидкістю. Після певної епохи рівень втрат на валідаційній вибірці припинив знижуватися, а пізніше показував мінімальне зростання, що може свідчити про початок перенавчання моделі. Це ставало причиною активації механізму ранньої зупинки.

Після зміни швидкості навчання друга ітерація розпочалася зі значно нижчих початкових значень втрат, порівняно з першою, що є очікуваним результатом, оскільки модель зберегла свої попередньо навчені параметри. Проте, на графіку подекуди спостерігається чіткий стрибок у значеннях втрат між першою та другою ітераціями. Це пояснюється адаптацією моделі до нових параметрів навчання, зокрема до зниженого коефіцієнта швидкості навчання. Такий ефект зазвичай пов'язаний з тим, що після різкої зміни гіперпараметрів алгоритми оптимізації можуть тимчасово демонструвати гірші показники, перш ніж стабілізуватися та продовжити поступове покращення.

Друга ітерація навчання показала значно стабільніший тренд у зменшенні втрат як на тренувальній, так і на валідаційній вибірках. Хоча швидкість їхнього зменшення була менш інтенсивною, ніж у першій ітерації, модель продовжувала покращуватися протягом тривалого періоду, що підтверджує ефективність застосування меншої швидкості навчання після початкового навчання. Під час другої ітерації модель уже перебуває у фазі донавчання, тобто вона вже знаходиться в області оптимальних або близьких до оптимальних значень параметрів. Через це зміни втрат стають менш помітними. Врешті-решт, зниження валідаційних втрат у другій ітерації свідчить про кращу узагальнюючу здатність моделі порівняно з першою ітерацією.

Таким чином, аналіз функції втрат навчання та валідації для всіх моделей сегментації підтвердив ефективність двоетапного підходу до навчання для поставленого завдання. Продемонстровані графіки з візуалізаціями динаміки втрат показують, як рання зупинка допомагає уникнути перенавчання, а зміна швидкості навчання дозволяє проводити ефективне донавчання. Варто зазначити, що представлені графіки відображають результати одного конкретного навчального процесу, і вони можуть дещо відрізнятися при повторному навчанні моделі. Такі відмінності можуть бути спричинені випадковістю ініціалізації ваг, специфікою розподілу даних у тренувальних і валідаційних наборах, а також випадковими факторами оптимізації. Проте загальна динаміка залишається подібною, що свідчить про передбачувану поведінку моделей та ефективність використаних обраних підходів до навчання моделей.

4.4. Опис експериментів за методом каскадної класифікації МРТзображень

Було проведено серію експериментів для оцінки ефективності різних методів класифікації патологій серця. Основна увага приділялася запропонованому

багатокроковому підходу, який використовує окремі класифікатори для поетапного класів. Цей підхід дозволяє оптимізувати процес класифікації, розділення розбиваючи складне багатокласове завдання на декілька більш простих етапів, що забезпечує високу точність і стабільність результатів. Для порівняння ефективності також було проведено додаткові експерименти, яких застосовувалися V мультикласові класифікатори на основі архітектур ResNet-50 та ResNet-18. Метою експериментів було визначити, наскільки ефективно моделі можуть цих класифікувати одразу всі п'ять класів без розбивання на етапи.

Першим експериментом було використання архітектури ResNet-50 для класифікації одразу п'яти класів патологій серця. Модель досягла загальної точності 84 %, що є прийнятним результатом, але значно поступається існуючим результатам. ResNet-50 добре справлялася з класифікацією нормальних станів серця (NOR) та аномального правого шлуночка (ARV), проте її ефективність суттєво знижувалася під час розпізнавання інфаркту міокарда зі зниженою фракцією викиду (MINF) та дилатаційної кардіоміопатії (DCM). Це пояснюється високою схожістю між цими класами, яку модель не змогла чітко врахувати без додаткових етапів оптимізації чи структуризації даних.

Матриця сплутування для мультикласового класифікатора на основі архітектури ResNet-50 представлена на рис. 4.24.



Рис. 4.24 – Матриця сплутування для мультикласового класифікатора на основі архітектури ResNet-50

Другим експериментом було тестування моделі ResNet-18, яка через свою меншу обчислювальну потужність і кількість параметрів продемонструвала ще нижчий рівень точності – 72 %. Цей результат виявився недостатнім, особливо для класифікації складних патологій, таких як перенесеного інфаркту міокарда (MINF), де модель мала високу частоту сплутаних результатів. Це свідчить про те, що ResNet-18 недостатньо потужна для завдань з високою складністю та потребує додаткової адаптації для ефективного вирішення подібних задач.

Матриця сплутування для мультикласового класифікатора на основі архітектури ResNet-18 представлена на рис. 4.25.



Рис. 4.25 – Матриця сплутування для мультикласового класифікатора на основі архітектури ResNet-18

Основна увага приділялася запропонованому багатокроковому підходу, який використовує окремі класифікатори для поетапного розділення класів. Цей підхід дозволяє оптимізувати процес класифікації, розбиваючи складне багатокласове завдання на декілька більш простих етапів, що забезпечує високу точність і стабільність результатів.

На рис. 4.26 представлена матриця сплутаності для кожного етапу класифікації, що демонструє кількість правильних, хибнопозитивних та хибнонегативних класифікацій.



Рис. 4.26 – Матриці сплутування: крок 1 – класифікатор 1; крок 2 – класифікатор 2; крок 3 – класифікатор 3; крок 4 – класифікатор 4

На першому етапі класифікації модель досягла загальної точності 0.96, успішно розділивши патології лівого шлуночка (такі, як перенесений інфаркт міокарда, гіпертрофічна та дилатаційна кардіоміопатії) від нормальних станів і аномалій правого шлуночка. Цей результат демонструє високу надійність моделі у визначенні великих груп патологій, що є основою для подальшої деталізації діагнозу.

Другий етап класифікації показав ідеальну точність (1.0) для розрізнення нормального стану серця (NOR) від аномалій правого шлуночка (ARV). Цей результат свідчить про абсолютну точність моделі в таких умовах і підкреслює її потенціал для швидкого виявлення патологій, які потребують негайної уваги.

Третій етап класифікації також досяг 1.0 у точності, повноті та F1-оцінці, ефективно розділивши гіпертрофічну кардіоміопатію (HCM) від інших патологій лівого шлуночка, таких як перенесений інфаркт міокарда (MINF) та дилатаційна кардіоміопатія (DCM). Це підкреслює здатність моделі розпізнавати специфічні патології серця, навіть за умов слабко виражених відмінностей між класами.

На четвертому етапі модель класифікувала перенесений інфаркт міокарда (MINF) і дилатаційну кардіоміопатію (DCM) з точністю 0.90. Хоча цей результат дещо нижчий порівняно з попередніми етапами, він все ж демонструє задовільну ефективність для розрізнення цих складних патологій, які часто перекриваються у візуальних і функціональних проявах.

Таблиця 4.13 демонструє результати класифікації запропонованої моделі на кожному етапі. Для кожного з чотирьох етапів класифікації метрики використовувалися для оцінки виявлення і розділення різних патологій серця.

Таблиця 4.13

Класифікатор	Клас	Precision	Recall	F ₁ score	Accuracy
Класифікатор 1	NOR+ARV	0.95	0.95	0.95	0.96
	MINF+HCM+DCM	0.97	0.97	0.97	0.90
Класифікатор 2	NOR	1.00	1.00	1.00	1.00
	ARV	1.00	1.00	1.00	1.00
Класифікатор 3	НСМ	1.00	1.00	1.00	1.00
	MINF+DCM	1.00	1.00	1.00	1.00
Класифікатор 4	MINF	0.90	0.90	0.90	0.90
	DCM	0.90	0.90	0.90	0.90

Метрики класифікаційної оцінки для класифікаторів 1–4,

На рис. 4.27 представлені ROC криві (receiver operating characteristic, робоча характеристика приймача) для кожного з чотирьох етапів класифікації, що ілюструють взаємозв'язок між чутливістю (справжня позитивна частота) та специфічністю (хибнопозитивна частота). Площа під кривою (AUC) для всіх класифікаторів підтверджує високу якість запропонованого підходу. AUC, що дорівнює 1.0 для етапів 2 та 3, підкреслює здатність моделі чітко розрізняти класи. Навіть на останньому етапі, де точність класифікації становила 0.90, AUC демонструє високу якість роботи моделі у розрізненні MINF та DCM. Площа під кривою (AUC) є важливим показником загальної якості моделі, оскільки вона відображає здатність моделі розрізняти класи.

отримані відповідно на етапах 1-4 у запропонованому методі класифікації.



Рис. 4.27 – Криві AUC для етапів класифікації: крок 1 – класифікатор 1; крок 2 – класифікатор 2; крок 3 – класифікатор 3; крок 4 – класифікатор 4

Порівняння загальної точності цього методу з результатами робіт інших авторів представлено в Таблиця 4.14. Загальна точність методу становить 97 %, що перевищує результати Khened et. al (96 %) і Zheng et al. (94 %), та Isensee et. al. (94 %). Це свідчить про конкурентоспроможність методу, особливо з огляду на те, що він демонструє стабільно високі результати на кожному етапі класифікації, що не завжди характерно для інших методів.

Таблиця 4.14

Порівняння результатів класифікації

Метод	Точність
Запропонований метод	97 %
Khened et. al. [140]	96 %
Zheng et. al. [141]	94 %
Isensee et. al. [136]	94 %

з сучасним рівнем техніки за коефіцієнтом Дайса.

Результати експериментів чітко демонструють перевагу багатокрокового підходу, який дозволяє покращити точність і стабільність класифікації навіть для складних патологій серця. Мультикласові класифікатори на основі ResNet-50 та ResNet-18, хоча і є стандартними інструментами в задачах класифікації, не змогли

досягти порівнянної точності через обмежену здатність до адаптації в умовах високої складності даних.

4.5. Опис експериментів за методом інтерпретації отриманих за моделями глибокого навчання рішень

Пропонується детально розглянути приклади інтерпретації отриманих результатів класифікації за запропонованим методом. Для аналізу результатів використовуються ознаки, запропоновані в моделі інтерпретації (підрозділ 3.2) для окремих патологій. Було проаналізовано 50 пацієнтів з тестового набору даних (по 10 для кожного класу). Далі наведено приклад аналізу конкретного пацієнта для кожного класу.

DCM (дилатаційна кардіоміопатія)

Основною ознакою дилатаційної кардіоміопатії є дилатація (збільшення об'єму та розмірів) порожнини лівого шлуночка зі зниженням його здатності скорочуватися. Аналіз рис. 4.28 показує, що діастолічний об'єм значно збільшений (222.59 мл, при нормі 100–200 мл для чоловіків, та 70–150 мл – для жінок) (ознака o_1^1). Відповідно, кінцевий систолічний об'єм також є підвищеним (156.01 мл, при нормі 30–100 мл) (ознака o_2^1). Також можна спостерігати значне зменшення фракції викиду (29 % при нормі вище 55–70 %), що явно вказує на визначену патологію (ознака o_3^1).

Маса міокарда (ознака o_4^1) знаходиться у межах норми (133.96 г), проте співвідношення маси міокарда до діастолічного об'єму знижене – 0.6 (ознака o_5^1), що підтверджує наявність дилатації.

У більшості випадків, стінка лівого шлуночка залишається нормальної товщини або навіть стає тоншою через розтягнення серцевого м'яза. З рисунка, а саме з моделі міокарда, можна побачити, що хоча загалом товщина стінки знаходиться в нормі, деякі фрагменти є тоншими ніж норма (позначається синім кольором), що додатково може підтверджувати наявність визначеної патології (ознака o_6^1).



На рис. 4.28 зображено приклад візуалізації патології DCM.

Рис. 4.28 – Інтерпретація результатів класифікації для патології DCM (дилатаційна кардіоміопатія)

НСМ (гіпертрофічна кардіоміопатія)

Типовими ознаками гіпертрофічної кардіоміопатії є асиметрична гіпертрофія міокарда та нерівномірність товщини стінок. Також інформативними ознаками можуть бути малий кінцевий систолічний об'єм (через ефективну скоротливість) та підвищення співвідношення маси міокарда до кінцевого систолічного об'єму.

На рис. 4.29 можна спостерігати, що кінцевий діастолічний об'єм лівого шлуночка становить 168.31 мл, що знаходиться у межах норми, але ближче до верхньої межі. Кінцевий систолічний об'єм лівого шлуночка – 27.05 мл (ознака o_1^2), що також відповідає нормі, однак свідчить про збережену ефективну скоротливість. Фракція викиду лівого шлуночка значно підвищена – 84 % (норма \geq 55 %, ознака o_2^2), що характерно для НСМ. Маса міокарда становить 183.08 г і перебуває у межах норми, проте співвідношення маси міокарда до кінцевого систолічного об'єму

підвищене до 6.05, що вказує на гіпертрофію зі зниженим систолічним об'ємом (ознака o_3^2).

З моделі міокарда можна побачити, що товщина стінки міокарда не рівномірна і спостерігаються надмірно потовщені ділянки (позначені червоним кольором) (ознаки o_4^2 , o_5^2 , o_6^2).

На рис. 4.29 зображено приклад візуалізації патології НСМ. Загалом у пацієнта наявні типові ознаки гіпертрофічної кардіоміопатії, які добре візуалізовані на зображенні, що підтверджує наявність визначеної патології.



Рис. 4.29 – Інтерпретація результатів класифікації для патології НСМ (гіпертрофічна кардіоміопатія)

MINF (інфаркт міокарда зі зниженою фракцією викиду)

Типовими ознаками міокардиту є знижена фракція викиду лівого шлуночка. Також важливою ознакою є наявність запалення, проте для його візуалізації використовують інший тип MPT-зображень (з використанням T2-сигналу). Проте про наявність запалення також може свідчити збільшена товщина міокарда. На рис. 4.30 у пацієнта можна спостерігати, що фракція викиду лівого шлуночка знижена до 26 % (норма \geq 55 %, ознака o_2^3), що є типовим для гострої стадії захворювання. Кінцевий діастолічний об'єм лівого шлуночка становить 178.17 мл, що знаходиться у межах норми, але ближче до верхньої межі (ознака o_1^3). Маса міокарда в кінцевій діастолі становить 182.44 г (ознака o_3^3), що відповідає нормі, проте це значення може бути підвищеним через набряк та запалення. Максимальна товщина стінки міокарда в діастолі – 12.57 мм, що знаходиться на верхній межі норми (ознака o_4^3), а підвищення середнього стандартного відхилення товщини міокарда до 2.06 мм свідчить про нерівномірний характер ураження (ознака o_5^3). Також нерівномірність товщини міокарда можна побачити на моделі міокарда (деякі сегменти позначені оранжевим кольором).

Таким чином, на рис. 4.30 продемонстровані візуалізації, що підкреслюють наявність патології MINF.



Рис. 4.30 – Інтерпретація результатів класифікації для патології MINF (інфаркт міокарда зі зниженою фракцією викиду)
ARV (аномальний правий шлуночок)

Ключовими ознаками ARV є дилатація правого шлуночка з одночасним зниженням його фракції викиду, значне збільшення об'єму правого шлуночка.

На рис. 4.31 у пацієнта кінцевий діастолічний об'єм правого шлуночка становить 219.58 мл, що значно перевищує норму (80–120 мл – для чоловіків), свідчачи про виражену дилатацію (ознака o_1^4). Кінцевий систолічний об'єм правого шлуночка також значно збільшений – 145.48 мл (норма <50 мл), що вказує на серйозне порушення систолічної функції. Фракція викиду правого шлуночка знижена до 34 % (норма >50 %), що є однією з ключових ознак дисфункції (ознака o_2^4).

Лівий шлуночок залишається відносно збереженим: його кінцевий діастолічний об'єм – 158.81 мл, кінцевий систолічний об'єм – 75.63 мл, а фракція викиду злегка знижена – 52 % (норма \geq 55 %). Однак співвідношення діастолічних об'ємів лівого та правого шлуночків становить лише 0.72 (норма 1.5–2.0), що свідчить про значне переважання дилатації правого шлуночка (ознака o_3^4). На рис. 4.31 зображено приклад візуалізації патології ARV.



Рис. 4.31 – Інтерпретація результатів класифікації для патології ARV (аномальний правий шлуночок).

Максимальна середня товщина стінки міокарда в кінцевій систолі становить 7.31 мм (норма 6–12 мм), що знаходиться в межах норми, але ближче до її нижньої межі (ознака o_4^4). Середнє стандартне відхилення товщини стінки міокарда в кінцевій систолі – 1.36 мм, що вказує на незначну варіабельність товщини стінки між сегментами (ознака o_5^4).

NOR (нормальний стан)

На рис. 4.32 зображено приклад візуалізації патології NOR. У пацієнта спостерігаються показники, які в цілому відповідають нормі.



Рис. 4.32 – Інтерпретація результатів класифікації для патології NOR (нормальний стан)

Лівий шлуночок має нормальні об'єми (125.51 мл, 41.75 мл) і збережену систолічну функцію (67 %) (ознаки o_1^5 , o_2^5 , o_4^5). Правий шлуночок має дещо підвищений діастолічний об'єм (172.41 мл) та злегка знижену фракцію викиду (45 %), що може бути варіантом індивідуальної норми (ознака o_3^5). Маса міокарда (119.56 г) і товщина стінок (10.82 мм у діастолі) також знаходяться у межах норми

(ознака o_5^5). Стандартне відхилення товщини стінок дещо підвищене (1.77 мм), але суттєвих структурних змін не виявлено. Загалом, наведені візуалізації підкреслюють відсутність значних патологічних ознак.

Тож для дилатаційної кардіоміопатії основні ознаки, як-от збільшення об'єму лівого шлуночка та зниження фракції викиду, легко визначаються як за числовими показниками, так і за візуалізацією, що підкреслює зміни у структурі серця. У випадку гіпертрофічної кардіоміопатії акцент зроблено на асиметричну гіпертрофію міокарда, надмірне потовщення його окремих сегментів i збільшення співвідношення маси міокарда до об'єму. Для міокардиту виявляються характерні зміни, як-от знижена фракція викиду та нерівномірність товщини стінок, що вказує на запальний процес. Ключові особливості, що свідчать про аномальність правого шлуночка, такі як значне збільшення його об'єму та зниження функції, стають очевидними завдяки аналізу наведених ознак та візуалізації. При нормальному стані результати класифікації підкреслюють збалансованість об'ємів, маси міокарда та нормальну скоротливу функцію. Відсутність значних відхилень дозволяє впевнено класифікувати цей стан як здоровий.

Хибна класифікація

Автоматична класифікація може інколи давати хибні результати через обмеження, описані в наступному розділі. На рис. 4.33 зображено приклад такої хибної класифікації. Пацієнт був класифікований як такий, що має гіпертрофічну кардіоміопатію (HCM) в той час, як насправді, за думкою експертів, які створювали набір даних, у пацієнта патологія відсутня. Аналіз рисунка показує, що деякі його параметри знаходяться на верхній межі норми. Маса міокарда (140.48 г) і співвідношення до кінцевого систолічного об'єму (2.0) могли нагадувати компенсаторну гіпертрофію, а товщина стінки міокарда в систолі (14.12 мм) – бути сприйняті як ознака HCM. Фракція викиду лівого шлуночка (60 %) дещо вища за середнє значення, що могло додатково сприяти хибному розпізнаванню. Невелике підвищення стандартного відхилення товщини стінок (1.37 мм) також могло вказувати на нерівномірність міокарда, характерну для HCM. Водночас, ключові ознаки захворювання, як-от асиметрична гіпертрофія та виражена зміна функції

серця, відсутні, тому ці параметри швидше відображають варіант норми, а не патологію.



Рис. 4.33 – Інтерпретація результатів класифікації (хибна класифікація)

Таким чином, запропоновані ознаки для інтерпретації результатів класифікації добре підкреслюють наявність виявленої патології, що дозволяє лікарю самостійно оцінити прийняте рішення і або погодитися з ним, або ні. Варто зазначити, що наявність відхилень для всіх запропонованих ознак не є обов'язковою для підтвердження патології. Варто враховувати анатомічні особливості пацієнтів, захворювання може протікати індивідуально, тож відсутність патології за необов'язково повністю конкретною ознакою виключає наявність патології. Присутність ознак, притаманних декільком патологіям також імовірна, як внаслідок перебігу кількох захворювань одночасно, так і через те, що деякі ознаки можуть бути варіантом норми для конкретного пацієнта (наприклад, вроджені аномалії чи інші індивідуальні особливості).

Запропонований підхід до інтерпретації та візуалізації результатів класифікації дозволяє представити діагностичну інформацію про ознаки, які використовуються у медичній практиці, та чітко підкреслює ключові відхилення від норми, забезпечуючи зручний аналіз для лікарів.

4.6. Обмеження запропонованих методів

Хоча запропоновані методи сегментації міокарда в лівому та правому шлуночках демонструють перспективність, існують певні обмеження, які потребують уваги.

1. Продуктивність моделі може значно погіршуватися під час обробки низькоякісних МРТ-зображень. Це особливо помітно, коли частини міокарда або шлуночків не повністю видимі, що приводить до неправильних сегментацій або повного пропуску цих областей. Модель значно залежить від виявлення відмінностей між цільовими структурами і навколишніми тканинами, тому погана якість МРТ-зображень серйозно впливає на точність.

2. Інша проблема виникає, коли рівні яскравості зображень занадто низькі або високі (рис. 4.34). У таких випадках модель може зіткнутися з труднощами у правильному визначенні меж серцевих структур, що приводить до погано окреслених сегментацій. Це відбувається тому, що при аналізі ділянки з недостатнім або надмірним рівнем яскравості, втрачаються важливі деталі, а, отже, негативно впливає на якість навчання.

3. Крім того, у даних, які використовувались для навчання моделей, була не достатня кількості прикладів певних патологічних станів, таких як кардіоміопатія або губчастий міокард. Ця нестача зразків може знизити здатність моделі до узагальнення для складних станів, що впливає на її надійність у клінічних умовах.



Рис. 4.34 – Зображення з недостатнім рівнем яскравості

4. На деяких зображеннях сегменти не візуалізуються або візуалізуються частково. Це пов'язано здебільшого з тим, що зріз був виконаний невдало, наприклад, у момент відкриття мітрального чи трикуспідального клапана. Якщо сегменти на зображенні не візуалізуються достатньо чітко, це може привести до помилкового рішення моделі. Наприклад, на рис. 4.35 можна побачити, що нижня частина міокарда погано візуалізується, проте на масці вона відмічена. Такі помилки можуть сприяти навчанню мережі самостійно доповнювати маску для подібних випадків.



Рис. 4.35 – Часткова візуалізація міокарда

Одним з ключових шляхів подолання обмежень запропонованих методів є покращення якості вхідних даних, адже продуктивність моделі значною мірою залежить від якості МРТ-зображень. Одним з можливих рішень є використання методів покращення контрастності та фільтрації шуму, що можуть підвищити видимість меж між міокардом та інших структур і навколишніми тканинами. Проте застосування алгоритмів покращення, таких як адаптивна нормалізація яскравості або генеративні методи відновлення втрачених фрагментів, може привести до спотворення первинних медичних даних, що є критичним у діагностичних задачах, і зменшити довіру до результатів аналізу.

Крім того, важливо забезпечити більш збалансований і різноманітний набір навчальних даних, особливо щодо рідкісних патологій. Це можна досягти за рахунок розширення вибірки пацієнтів або застосування технік аугментації даних, однак надмірне використання синтетичних прикладів може вплинути на здатність моделі узагальнювати реальні випадки, що також зменшує довіру до системи. Ще одним важливим напрямом є вдосконалення методів сегментації шляхом використання мультимодальних підходів, зокрема комбінування інформації з різних режимів МРТ, або інтеграція додаткових анатомічних знань у процес навчання моделі. Такі підходи можуть знизити залежність алгоритмів від варіацій у яскравості та контрастності, однак вони також підвищують складність моделі і вимоги до обчислювальних ресурсів.

Таким чином, хоча й існують ефективні технічні рішення для покращення сегментації, необхідно враховувати ризики, пов'язані зі зміною вхідних даних, які можуть привести до втрати клінічної достовірності результатів. Баланс між покращенням якості та збереженням автентичності зображень є ключовим для підвищення надійності моделі в реальних медичних умовах. Хоча описані підходи є надійними за ідеальних умов, їхня ефективність значною мірою залежить від якості вхідних даних. Особлива обережність потрібна під час роботи з низькоякісними зображеннями або рідкісними патологіями, оскільки це може знижувати точність і робити модель менш надійною в критичних діагностичних ситуаціях.

4.7. Висновки до розділу 4

У ході проведених експериментів було досліджено вплив кожного етапу запропонованого методу сегментації – від роботи з оригінальними зображеннями до комплексного підходу, який включає локалізацію, декомпозицію та постобробку. Кожен етап експериментів зробив свій внесок у покращення точності сегментації серцевих структур, що підтверджено за допомогою коефіцієнта Дайса для фаз кінцевої діастоли та кінцевої систоли. На першому етапі, при сегментації оригінальних зображень без локалізації чи декомпозиції, модель показала обмежену точність через вплив фонових шумів і змішування структур. Останній етап, що включав локалізацію, декомпозицію масок та постобробку, показав найкращі результати. Запропонований метод дозволив усунути залишкові артефакти, згладити контури та покращити узгодженисть отриманих масок з експертними. Це підтвердило ефективність запропонованого методу, який поєднує всі ключові етапи обробки: локалізацію, декомпозицію і постобробку. Запропонований метод сегментації досяг високих показників точності: коефіцієнт Дайса для лівого шлуночка становив 0.974 у фазі кінцевої діастоли та 0.940 – у фазі кінцевої систоли. Для правого шлуночка результати склали 0.947 та 0.915, відповідно. Міокард лівого шлуночка був сегментований з точністю 0.896 у фазі діастоли та 0.920 – у фазі систоли, що робить його перспективним інструментом для застосування у клінічній практиці та подальших наукових дослідженнях. За висновком практикуючого кардіолога, 97.73 % масок мають задовільну та достатню якість для проведення аналізу медичним спеціалістом. Решта 2.27 % масок мають гірші результати більшою мірою через погану якість вхідного зображення, а саме: погану візуалізацію серця через низьку роздільну здатність; артефакти зображення, такі як розмиття тощо (через рух пацієнта під час проведення МРТ-дослідження); низьку яскравість або контрастність зображення (внаслідок особливостей МРТ-апарата або складнощі проведення дослідження для конкретного пацієнта).

Запропонований багатокроковий підхід до класифікації патологій серця демонструє високу ефективність у розв'язанні задач сегментації та діагностики.

Використання окремих класифікаторів на кожному з етапів дозволило досягти значної точності і стабільності результатів, навіть для складних випадків. Модель досягла загальної точності 97 %, що перевищує більшість сучасних підходів, літературі. Додаткові iз представлених v експерименти застосуванням мультикласових класифікаторів ResNet-50 та ResNet-18 виявили їхні обмеження. ResNet-50 досяг точності 84 %, що вказує на проблеми з розрізненням схожих інфаркт міокарда класів. таких ЯК перенесений (MINF) та дилатаційна кардіоміопатія (DCM). ResNet-18, через меншу кількість параметрів, показав ще нижчий результат – 72 %, що свідчить про її недостатню потужність для складних задач класифікації. Це підкреслює перевагу запропонованого підходу, який, завдяки поетапному розділенню, задач дозволяє ефективно враховувати особливості Порівняння підтвердило кожного класу. iз сучасними методами конкурентоспроможність запропонованої методики. Висока точність та адаптивність підходу роблять його перспективним для інтеграції в клінічну практику, де важлива як висока якість класифікації, так і здатність ефективно працювати із складними медичними даними.

Розроблений підхід до візуалізації дозволяє наочно та структуровано представити результати аналізу медичних даних. Використання адаптивних методів візуалізації, таких як 17-сегментна модель, кругові діаграми та числові значення, забезпечує інтуїтивне розуміння результатів лікарями. Така форма подання спрощує діагностичний процес і сприяє інтеграції отриманих результатів у клінічну практику.

ВИСНОВКИ

Метою дослідження було визначено підвищення точності сегментації та класифікації МРТ-зображення серця та отримання можливості інтерпретації отриманих за моделями глибокого навчання рішень. Для подолання описаних недоліків та досягнення поставленої мети було виконано такі завдання:

1. Проведено аналіз сучасного стану методів і засобів глибокого навчання, що використовуються для обробки та аналізу медичних зображень, зокрема МРТ-серця, та виявлення патологій, а також методів інтерпретації результатів систем штучного інтелекту.

Огляд підтвердив перспективність методів глибокого навчання, зокрема глибоких нейронних мереж, у вирішенні задач сегментації та класифікації завдяки їхній здатності виявляти складні патерни. Водночас, було виявлено низку проблем, пов'язаних із залежністю від якісних анотованих даних, обчислювальною складністю моделей і недостатньою інтерпретованістю результатів, що ускладнює їхню інтеграцію в клінічну практику.

2. Розроблено метод багатоступеневої сегментації області серця на МРТзображенні на регіони правого і лівого шлуночків та міокарда з подальшою постобробкою гаусівським згладжування для уточнення контурів і зменшення артефактів.

Запропонований багатоступеневий метод сегментації, який поєднує архітектури U-Net та ResNet, що дозволило досягти високої точності у виділенні ключових структур серця – лівого і правого шлуночків і міокарда. Використання окремих моделей для кожної області та створення модифікованих наборів даних шляхом попередньої обробки забезпечили баланс між якістю результатів та обчислювальними витратами.

3. Розроблено метод каскадної класифікації патологій: дилатаційна кардіоміопатія (DCM), гіпертрофічна кардіоміопатія (HCM), інфаркт міокарда зі зниженою фракцією викиду (MINF), аномальний правий шлуночок (ARV) на MPT-

зображенні для більш точного розрізнення захворювань серця з використанням сегментованих даних МРТ.

Розроблений каскадний метод класифікації, заснований на чотирьох бінарних класифікаторах, дозволив поетапно розділяти класи патологій. Такий підхід знижує ризик плутанини між класами в умовах обмеженого обсягу даних і враховує анатомічні особливості серця, що є критично важливим для діагностики.

4. Розроблено метод інтерпретації отриманих за глибоким навчанням рішень за ознаками, які використовуються у медичній практиці.

Розроблений метод інтерпретації рішень підвищив довіру до результатів моделей глибокого навчання на основі медичних ознак, які використовуються в медичній практиці. Результати представлені у зрозумілій формі, включаючи числові показники, кругові діаграми та візуалізацію у 17-сегментній моделі міокарда, що сприяє довірі медичних спеціалістів до рішень штучного інтелекту та їхній інтеграції в клінічну практику.

5. Проведено експериментальні дослідження спроможності розроблених методів вирішувати поставлену задачу з потрібною якістю та відповідною інтерпретованістю.

Експериментальні результати підтвердили ефективність запропонованих методів. Багатоступеневий метод сегментації досяг високих показників точності за коефіцієнтом Дайса, а якість сегментованих масок була оцінена кардіологами як задовільна у 97.73 % випадків. Метод каскадної класифікації перевершив традиційні мультикласові класифікатори, демонструючи вищу точність та стабільність результатів, досягнувши загальної точності 97 %.

Таким чином, дослідження досягло поставленої мети – створено ефективні методи обробки та аналізу МРТ-зображень серця, які поєднують високу якість діагностики з інтерпретованістю результатів та можливістю практичного застосування. Розроблені підходи мають значний потенціал для покращення діагностики серцево-судинних захворювань і сприяють розвитку пояснювального штучного інтелекту в медицині.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Explainable Deep Learning: A Visual Analytics Approach with Transition Matrices / P. Radiuk et al. *Mathematics*. 2024. P. 1024. URL: <u>https://doi.org/10.3390/math12071024</u> (date of access: 27.11.2024).

 Improving Diagnosis in Health Care / ed. by E. P. Balogh, B. T. Miller, J. R. Ball.
 Washington, D.C. National Academies Press, 2015. URL: <u>https://doi.org/10.17226/21794</u> (date of access: 13.03.2025).

3. Invisible numbers: the true extent of noncommunicable diseases and what to do about them. World Health Organization. URL: <u>https://iris.who.int/bitstream/handle/10665/362800/9789240057661-eng.pdf</u> (date of access: 13.03.2025).

4. Counseller Q., Aboelkassem Y. Recent technologies in cardiac imaging.Frontiers in Medical Technology.2023.Vol.4.URL:https://doi.org/10.3389/fmedt.2022.984492(date of access: 13.03.2025).

5. Quantitative cardiac MRI / A. Seraphim et al. *Journal of Magnetic Resonance Imaging*. 2019. Vol. 51, no. 3. P. 693–711. URL: <u>https://doi.org/10.1002/jmri.26789</u> (date of access: 13.03.2025).

6. Standardized cardiovascular magnetic resonance imaging (CMR) protocols: 2020 update / C. M. Kramer et al. *Journal of Cardiovascular Magnetic Resonance*. 2020. Vol. 22, no. 1. URL: <u>https://doi.org/10.1186/s12968-020-00607-1</u> (date of access: 13.03.2025).

7. McGee K. P., Bernstein M. A. Common MR Imaging Artifacts. *Mayo Clinic Guide to Cardiac Magnetic Resonance Imaging*. 2015. P. 231–245. URL: <u>https://doi.org/10.1093/med/9780199941186.003.0012</u> (date of access: 13.03.2025).

8. FitzGerald C., Hurst S. Implicit bias in healthcare professionals: a systematic review. *BMC Medical Ethics*. 2017. Vol. 18, no. 1. URL: <u>https://doi.org/10.1186/s12910-017-0179-8</u> (date of access: 13.03.2025).

9. Unconscious Bias among Health Professionals: A Scoping Review / U. Meidert et al. *International Journal of Environmental Research and Public Health*. 2023. Vol. 20, No. 16. P. 6569. URL: <u>https://doi.org/10.3390/ijerph20166569</u> (date of access: 13.03.2025).

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: <u>https://doi.org/10.1016/j.bspc.2024.106325</u> (date of access: 13.03.2025).

11. 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: <u>https://doi.org/10.15588/1607-3274-2024-1-10</u> (date of access: 13.03.2025).

12. An Approach toward Automatic Specifics Diagnosis of Breast Cancer Based on an Immunohistochemical Image / O. Berezsky et al. *Journal of Imaging*. 2023. Vol. 9, no. 1. P. 12. URL: <u>https://doi.org/10.3390/jimaging9010012</u> (date of access: 13.03.2025).

13. Method and Software Tool for Generating Artificial Databases of BiomedicalImages Based on Deep Neural Networks / O. M. Berezsky et al. International WorkshoponInformatics& Data-DrivenMedicine.2024.URL:https://api.semanticscholar.org/CorpusID:270062657 (date of access: 13.03.2025).

14. 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: <u>https://doi.org/10.3390/technologies12070112</u> (date of access: 13.03.2025).

15. A cascade ensemble-learning model for the deployment at the edge: case onmissing IoT data recovery in environmental monitoring systems / I. Izonin et al. FrontiersinEnvironmentalScience.2023.Vol.11.URL:https://doi.org/10.3389/fenvs.2023.1295526(date of access: 13.03.2025).

16. Algorithmization and Optimization Models of Patient-Centric Rehabilitation Programs* / D. V. Vakulenko et al. *Cybernetics and Systems Analysis*. 2024. URL: <u>https://doi.org/10.1007/s10559-024-00711-5</u> (date of access: 13.03.2025).

17. 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: 13.03.2025).

18. AVRUNIN O. Using a priori data for segmentation anatomical structures of the brain. *PRZEGLĄD ELEKTROTECHNICZNY*. 2017. Vol. 1, no. 5. P. 104–107. URL: <u>https://doi.org/10.15199/48.2017.05.20</u> (date of access: 13.03.2025).

19. 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: <u>https://doi.org/10.3390/s21041198</u> (date of access: 13.03.2025).

20. Zheng Q., Delingette H., Ayache N. Explainable cardiac pathology classification on cine MRI with motion characterization by semi-supervised learning of apparent flow. *Medical Image Analysis*. 2019. Vol. 56. P. 80–95. URL: <u>https://doi.org/10.1016/j.media.2019.06.001</u> (date of access: 13.03.2025).

21. Automatic Cardiac Disease Assessment on cine-MRI via Time-Series Segmentation and Domain Specific Features / F. Isensee et al. *Lecture Notes in Computer Science*. Cham, 2018. P. 120–129. URL: <u>https://doi.org/10.1007/978-3-319-75541-0_13</u> (date of access: 13.03.2025).

22. Revolutionizing Cardiac Imaging: A Scoping Review of Artificial Intelligence in Echocardiography, CTA, and Cardiac MRI / A. Moradi et al. *Journal of Imaging*. 2024. Vol. 10, no. 8. P. 193. URL: <u>https://doi.org/10.3390/jimaging10080193</u> (date of access: 13.03.2025).

23. 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: <u>https://doi.org/10.1109/tmi.2018.2837502</u> (date of access: 13.03.2025).

24. Ultrafast Cardiac Imaging Using Deep Learning For Speckle-Tracking Echocardiography / J. Lu et al. *IEEE Transactions on Ultrasonics*, Ferroelectrics, and Frequency Control. 2023. P. 1. URL: <u>https://doi.org/10.1109/tuffc.2023.3326377</u> (date of access: 13.03.2025).

25. Echocardiography Segmentation with Enforced Temporal Consistency / N. Painchaud et al. *IEEE Transactions on Medical Imaging*. 2022. P. 1. URL: <u>https://doi.org/10.1109/tmi.2022.3173669</u> (date of access: 13.03.2025).

26. Cardiac Segmentation With Strong Anatomical Guarantees / N. Painchaud et al. *IEEE Transactions on Medical Imaging*. 2020. Vol. 39, no. 11. P. 3703–3713. URL: <u>https://doi.org/10.1109/tmi.2020.3003240</u> (date of access: 13.03.2025).

27. Cardiac MRI findings to differentiate athlete's heart from hypertrophic (HCM), arrhythmogenic right ventricular (ARVC) and dilated (DCM) cardiomyopathy / J. Kübler et al. *The International Journal of Cardiovascular Imaging*. 2021. Vol. 37, No. 8. P. 2501–2515. URL: <u>https://doi.org/10.1007/s10554-021-02280-6</u> (date of access: 13.03.2025).

28. Improved visualization of hepatic tumors in magnetic resonance-guided thermoablation using T1-inversion-recovery imaging with variable inversion time / J. Kübler et al. *European Radiology*. 2023. URL: <u>https://doi.org/10.1007/s00330-023-09696-9</u> (date of access: 13.03.2025).

29. Rajiah P. S., François C. J., Leiner T. Cardiac MRI: State of the Art. *Radiology*. 2023. URL: <u>https://doi.org/10.1148/radiol.223008</u> (date of access: 10.03.2025).

30. Слободзян В. О., Бармак О. В. Метод класифікації МРТ-зображень серця за каскадними моделями глибокого навчання. *Оптико-електронні-інформаційно-енергетичні технології*. 2024. Т. 48, Вип. 2. С. 104–113. DOI: 10.31649/1681-7893-2024-48-2-104-113 (дата звернення: 26.01.2025).

31. Слободзян В. О., Бармак О. В. Метод сегментації МРТ серця на основі локалізації масок. *Вісник Хмельницького національного університету*. 2024. Т. 343, № 6 (1). С. 288–294. DOI: 10.31891/2307-5732-2024-343-6-43 (дата звернення: 26.01.2025).

32. Slobodzian V., Barmak O. Method for interpreting decisions made by deep learning models. *Computer systems and information technologies*. 2024. № 4. C. 150–156. DOI: 10.31891/csit-2024-4-18 (date of access: 13.03.2025).

33. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis / P. Radiuk et al. *5th International Conference on Informatics and Data-Driven Medicine, IDDM 2022* : Conference Proceedings, Lyon, 18–20 November 2022. 2022. P. 9–20. URL: <u>https://ceur-ws.org/Vol-3302/paper1.pdf</u> (date of access: 13.03.2025).

34. Myocardium Segmentation using Two-Step Deep Learning with Smoothed Masks by Gaussian Blur / V. Slobodzian et al. 6th International Conference on

Informatics and Data-Driven Medicine, IDDM 2023: Conference Proceedings, Bratislava, 17–19 November 2022. 2023. P. 77–91. URL: <u>https://ceur-ws.org/Vol-3609/paper7.pdf</u> (date of access: 13.03.2025).

35. Multi-Stage Segmentation and Cascade Classification Methods for Improving Cardiac MRI Analysis / V. Slobodzian et al. *Information Technology and Implementation* (*IT&I-2024*) : Conference Proceedings, 20–21 November 2024. Kyiv, 2024. URL: <u>https://arxiv.org/pdf/2412.09386</u> (date of access: 13.03.2025).

36. Комп'ютерна програма «Класифікація МРТ на наявність патологій з подальшою інтерпретацією результатів» : а. с. 133517 Україна : CR2584180225 / В. О. Слободзян, О. В. Бармак, П. М. Радюк. № с202410411 ; заявл. 20.12.2024 ; опубл. 18.02.2025. 20 с.

37. Medical Images Edge Detection Based on Mathematical Morphology / Zhao Yuqian et al. 2005 *IEEE Engineering in Medicine and Biology 27th Annual Conference*, Shanghai, China, 17–18 January 2006. 2005. URL: <u>https://doi.org/10.1109/iembs.2005.1615986</u> (date of access: 13.03.2025).

38. Threshold-Based Level Set Method of Image Segmentation / A. Xu et al. 20103rd International Conference on Intelligent Networks and Intelligent Systems (ICINIS),Shenyang,China,1-3November2010.2010.URL:https://doi.org/10.1109/icinis.2010.181 (date of access: 13.03.2025).

39. Cigla C., Alatan A. A. Region-based image segmentation via graph cuts. 2008 15th *IEEE International Conference on Image Processing*, San Diego, CA, USA, 12–15 October 2008. 2008. URL: <u>https://doi.org/10.1109/icip.2008.4712244</u> (date of access: 13.03.2025).

40. A Review of Deep-Learning-Based Medical Image Segmentation Methods / X. Liu et al. *Sustainability*. 2021. Vol. 13, no. 3. P. 1224. URL: <u>https://doi.org/10.3390/su13031224</u> (date of access: 13.03.2025).

41. Khan A. R. Facial Emotion Recognition Using Conventional Machine Learning and Deep Learning Methods: Current Achievements, Analysis and Remaining Challenges. *Information*. 2022. Vol. 13, no. 6. P. 268. URL: <u>https://doi.org/10.3390/info13060268</u> (date of access: 13.03.2025).

42. Towards Clinician-Preferred Segmentation: Leveraging Human-in-the-Loop for Test Time Adaptation in Medical Image Segmentation / S. Hu et al. *ArXiv*. 2024. Abs/2405.08270. URL: <u>https://api.semanticscholar.org/CorpusID:269761934</u>.

43. Deep Learning for Cardiac Image Segmentation: A Review / C. Chen et al. *Frontiers in Cardiovascular Medicine*. 2020. Vol. 7. URL: <u>https://doi.org/10.3389/fcvm.2020.00025</u> (date of access: 13.03.2025).

44. Pandey S., Chen K.-F., Dam E. B. Comprehensive Multimodal Segmentation in Medical Imaging: Combining YOLOv8 with SAM and HQ-SAM Models. 2023 *IEEE/CVF International Conference on Computer Vision Workshops* (ICCVW), Paris, France, 2–6 October 2023. URL: https://doi.org/10.1109/iccvw60793.2023.00273 (date of access: 13.03.2025).

45. Tian Y., Krishnan D., Isola P. Contrastive Multiview Coding. *CoRR*. 2019. Abs/1906.05849. URL: <u>http://arxiv.org/abs/1906.05849</u> (date of access: 13.03.2025).

46. Improved Baselines with Momentum Contrastive Learning / X. Chen et al. *CoRR*. 2020. Abs/2003.04297. URL: <u>https://arxiv.org/abs/2003.04297</u> (date of access: 13.03.2025).

47. A Simple Framework for Contrastive Learning of Visual Representations / T. Chen et al. *CoRR*. 2020. Abs/2002.05709. URL: <u>https://arxiv.org/abs/2002.05709</u> (date of access: 13.03.2025).

48. Propagate Yourself: Exploring Pixel-Level Consistency for Unsupervised Visual Representation Learning / Z. Xie et al. *CoRR*. 2020. Abs/2011.10043. URL: https://arxiv.org/abs/2011.10043 (date of access: 13.03.2025).

49. Cuts: A fully unsupervised framework for medical image segmentation / C. Liu et al. arXiv preprint arXiv:2209.11359. 2022.

50. Self-Supervised-RCNN for Medical Image Segmentation with Limited Data Annotation / B. Felfeliyan et al. URL: <u>https://arxiv.org/abs/2207.11191</u> (date of access: 13.03.2025).

51. Bootstrap Your Own Latent: A New Approach to Self-Supervised Learning / J.-B. Grill et al. *CoRR*. 2020. Abs/2006.07733. URL: <u>https://arxiv.org/abs/2006.07733</u> (date of access: 13.03.2025).

52. Hasan S. M. K., Linte C. A. Learning Deep Representations of Cardiac Structures for 4D Cine MRI Image Segmentation through Semi-Supervised Learning. *Applied Sciences*. 2022. Vol. 12, No. 23. P. 12163. URL: <u>https://doi.org/10.3390/app122312163</u> (date of access: 13.03.2025).

53. Optimized Automated Cardiac MR Scar Quantification with GAN-Based Data Augmentation / D. R. P. R. M. Lustermans et al. *Computer Methods and Programs in Biomedicine*. 2022. P. 107116. URL: <u>https://doi.org/10.1016/j.cmpb.2022.107116</u> (date of access: 13.03.2025).

54. ViT-FRD: A Vision Transformer Model for Cardiac MRI Image Segmentation Based on Feature Recombination Distillation / C. Fan et al. *IEEE Access*. 2023. P. 1. URL: <u>https://doi.org/10.1109/access.2023.3302522</u> (date of access: 13.03.2025)..

55. Causality-inspired Single-source Domain Generalization for Medical Image Segmentation / C. Ouyang et al. *IEEE Transactions on Medical Imaging*. 2022. P. 1. URL: <u>https://doi.org/10.1109/tmi.2022.3224067</u> (date of access: 13.03.2025).

56. Segmentation of 4D Flow MRI: Comparison between 3D Deep Learning and Velocity-Based Level Sets / A. *Barrera-Naranjo et al. Journal of Imaging*. 2023. Vol. 9, no. 6. P. 123. URL: <u>https://doi.org/10.3390/jimaging9060123</u> (date of access: 13.03.2025).

57. Effective extraction of ventricles and myocardium objects from cardiac magnetic resonance images with a multi-task learning U-Net / J. Ren et al. *Pattern Recognition Letters*. 2022. Vol. 155. P. 165–170. URL: <u>https://doi.org/10.1016/j.patrec.2021.10.025</u> (date of access: 13.03.2025).

58. A Novel Light U-Net Model for Left Ventricle Segmentation Using MRI / M. Irshad et al. *Mathematics*. 2023. Vol. 11, no. 14. P. 3245. URL: <u>https://doi.org/10.3390/math11143245</u> (date of access: 13.03.2025).

59. Label-informed cardiac magnetic resonance image synthesis through conditional generative adversarial networks / S. Amirrajab et al. *Computerized Medical Imaging and Graphics*. 2022. P. 102123. URL: <u>https://doi.org/10.1016/j.compmedimag.2022.102123</u> (date of access: 13.03.2025).

60. A Framework for Simulating Cardiac MR Images with Varying Anatomy and Contrast / S. Amirrajab et al. *IEEE Transactions on Medical Imaging*. 2022. P. 1. URL: <u>https://doi.org/10.1109/tmi.2022.3215798</u> (date of access: 13.03.2025).

61. Deep Learning Segmentation of the Right Ventricle in Cardiac MRI: The M&ms Challenge / C. Martín-Isla et al. *IEEE Journal of Biomedical and Health Informatics*. 2023. P. 1–14. URL: <u>https://doi.org/10.1109/jbhi.2023.3267857</u> (date of access: 13.03.2025).

62. Reducing segmentation failures in cardiac MRI via Late feature fusion and GANbased augmentation / Y. Al Khalil et al. *Computers in Biology and Medicine*. 2023. P. 106973. URL: <u>https://doi.org/10.1016/j.compbiomed.2023.106973</u> (date of access: 13.03.2025).

63. Hasan S. M. K., Linte C. A. Joint Segmentation and Uncertainty Estimation of Ventricular Structures from Cardiac MRI using a Bayesian CondenseUNet. 2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), Glasgow, Scotland, United Kingdom, 11–15 July 2022. 2022. URL: https://doi.org/10.1109/embc48229.2022.9871780 (date of access: 13.03.2025).

64. HDL: Hybrid Deep Learning for the Synthesis of Myocardial Velocity Maps in Digital Twins for Cardiac Analysis / X. Xing et al. *IEEE Journal of Biomedical and Health Informatics*. 2022. P. 1. URL: <u>https://doi.org/10.1109/jbhi.2022.3158897</u> (date of access: 13.03.2025).

65. Arega T. W., Bricq S., Meriaudeau F. Automatic Quality Assessment of Cardiac MR Images with Motion Artefacts Using Multi-task Learning and K-Space Motion Artefact Augmentation. *Statistical Atlases and Computational Models of the Heart. Regular and CMRxMotion Challenge Papers*. Cham, 2022. P. 418–428. URL: <u>https://doi.org/10.1007/978-3-031-23443-9_39</u> (date of access: 13.03.2025).

66. CE-Net: Context Encoder Network for 2D Medical Image Segmentation / Z. Gu et al. *IEEE Transactions on Medical Imaging*. 2019. Vol. 38, no. 10. P. 2281–2292. URL: <u>https://doi.org/10.1109/tmi.2019.2903562</u> (date of access: 13.03.2025).

67. Devi W., Roy S., Thongam K. Multi-Scale Dilated Fusion Network (MSDFN) for Automatic Instrument Segmentation. *Journal of Computer Science and Technology Studies*. 2022. Vol. 4, no. 1. P. 66–72. URL: <u>https://doi.org/10.32996/jcsts.2022.4.1.7</u> (date of access: 13.03.2025).

68. Chen X., Xu C. Multi-Encoder U-Net for Automatic Kidney Tumor Segmentation. 2019 Kidney Tumor Segmentation Challenge: KiTS19. 2019. URL: <u>https://doi.org/10.24926/548719.024</u> (date of access: 13.03.2025).

69. Deep Residual Learning for Image Recognition / K. He et al. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 27–30 June 2016. 2016. URL: <u>https://doi.org/10.1109/cvpr.2016.90</u> (date of access: 13.03.2025).

70. Huang G., Liu Z., Weinberger K. Q. Densely Connected Convolutional Networks. *CoRR*. 2016. Abs/1608.06993. URL: <u>http://arxiv.org/abs/1608.06993</u> (date of access: 13.03.2025).

71. Cancer image classification based on DenseNet model / Z. Zhong et al. *Journal* of *Physics: Conference Series*. 2020. Vol. 1651. P. 012143. URL: <u>https://doi.org/10.1088/1742-6596/1651/1/012143</u> (date of access: 13.03.2025).

72. Zheng Q., Delingette H., Ayache N. Explainable cardiac pathology classification on cine {MRI} with motion characterization by semi-supervised learning of apparent flow. *CoRR*. 2018. Abs/1811.03433. URL: <u>http://arxiv.org/abs/1811.03433</u> (date of access: 13.03.2025).

73. Khened M., Kollerathu V. A., Krishnamurthi G. Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers. *Medical Image Analysis*. 2019. Vol. 51. P. 21–45. URL: <u>https://doi.org/10.1016/j.media.2018.10.004</u> (date of access: 13.03.2025).

74. B 2 C 3 NetF 2 : Breast cancer classification using an end-to-end deep learning feature fusion and satin bowerbird optimization controlled Newton Raphson feature selection / M. Fatima et al. *CAAI Transactions on Intelligence Technology*. 2023. URL: <u>https://doi.org/10.1049/cit2.12219</u> (date of access: 29.11.2024.

75. Improving RepVGG model with variational data imputation in COVID-19 classification / K. Trang et al. *IAES International Journal of Artificial Intelligence (IJ-AI)*. 2022. Vol. 11, no. 4. P. 1278. URL: <u>https://doi.org/10.11591/ijai.v11.i4.pp1278-1286</u> (date of access: 13.03.2025).

76. Enhancing Brain Tumor Classification with Transfer Learning across Multiple Classes: An In-Depth Analysis / S. Ahmmed et al. *BioMedInformatics*. 2023. Vol. 3, no. 4. P. 1124–1144. URL: <u>https://doi.org/10.3390/biomedinformatics3040068</u> (date of access: 13.03.2025).

77. A Step Towards Automated Haematology: DL Models for Blood Cell Detection and Classification / I. S. Rahat et al. *EAI Endorsed Transactions on Pervasive Health and Technology*. 2024. Vol. 10. URL: <u>https://doi.org/10.4108/eetpht.10.5477</u> (date of access: 13.03.2025).

78. Jeny A. A., Junayed M. S., Islam M. B. Deep Neural Network-Based Ensemble Model for Eye Diseases Detection and Classification. *Image Analysis & Stereology*. 2023.
Vol. 42, no. 2. P. 77–91. URL: <u>https://doi.org/10.5566/ias.2857</u> (date of access: 13.03.2025).

79. LCDEiT: A Linear Complexity Data-Efficient Image Transformer for MRI Brain Tumor Classification / G. J. Ferdous et al. *IEEE Access*. 2023. P. 1. URL: <u>https://doi.org/10.1109/access.2023.3244228</u> (date of access: 13.03.2025).

80. Understanding the brain with attention: A survey of transformers in brain sciences / C. Chen et al. *Brain-X*. 2023. Vol. 1, no. 3. URL: <u>https://doi.org/10.1002/brx2.29</u> (date of access: 13.03.2025).

81. An investigation into augmentation and preprocessing for optimising X-ray classification in limited datasets: a case study on necrotising enterocolitis / F. Nowak et al. *International Journal of Computer Assisted Radiology and Surgery*. 2024. URL: <u>https://doi.org/10.1007/s11548-024-03107-0</u> (date of access: 13.03.2025).

82. Unsupervised many-to-many stain translation for histological image augmentation to improve classification accuracy / M. Berijanian et al. *Journal of Pathology Informatics*. 2023. P. 100195. URL: <u>https://doi.org/10.1016/j.jpi.2023.100195</u> (date of access: 13.03.2025).

83. Classification of Breast Cancer Histopathological Images Using DenseNet and Transfer Learning / M. A. Wakili et al. *Computational Intelligence and Neuroscience*. 2022. Vol. 2022. P. 1–31. URL: <u>https://doi.org/10.1155/2022/8904768</u> (date of access: 13.03.2025).

84. Classification of skin cancer from dermoscopic images using deep neural network architectures / J. S M et al. *Multimedia Tools and Applications*. 2022. URL: <u>https://doi.org/10.1007/s11042-022-13847-3</u> (date of access: 13.03.2025).

85. Marques G., Agarwal D., de la Torre Díez I. Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network. *Applied Soft Computing*. 2020. Vol. 96. P. 106691. URL: <u>https://doi.org/10.1016/j.asoc.2020.106691</u> (date of access: 13.03.2025).

86. Wang M., Gong X. Metastatic Cancer Image Binary Classification Based on Resnet Model. 2020 IEEE 20th International Conference on Communication Technology (ICCT), Nanning, China, 28–31 October 2020. 2020. URL: https://doi.org/10.1109/icct50939.2020.9295797 (date of access: 13.03.2025).

87. Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer / D. Sarwinda et al. *Procedia Computer Science*. 2021. Vol. 179. P. 423–431. URL: <u>https://doi.org/10.1016/j.procs.2021.01.025</u> (date of access: 13.03.2025).

88. Nithya V. P., Mohanasundaram N., Santhosh R. An Early Detection and Classification of Alzheimer's Disease Framework Based on ResNet-50. *Current Medical Imaging Formerly Current Medical Imaging Reviews*. 2023. Vol. 20. URL: <u>https://doi.org/10.2174/1573405620666230825113344</u> (date of access: 13.03.2025).

89. Brain Tumor Classification & Segmentation by Using Advanced DNN, CNN & ResNet-50 Neural Networks. *International Journal of Circuits, Systems and Signal Processing*. 2020. Vol. 14. URL: <u>https://doi.org/10.46300/9106.2020.14.129</u> (date of access: 13.03.2025).

90. Improving disease classification performance and explainability of deep learning models in radiology with heatmap generators / A. Watanabe et al. *Frontiers in Radiology*. 2022. Vol. 2. URL: <u>https://doi.org/10.3389/fradi.2022.991683</u> (date of access: 13.03.2025).

91. Clinician's guide to trustworthy and responsible artificial intelligence in cardiovascular imaging / L. Szabo et al. *Frontiers in Cardiovascular Medicine*. 2022. Vol. 9. URL: https://doi.org/10.3389/fcvm.2022.1016032 (date of access: 13.03.2025).

92. Interpretability of a deep learning model in the application of cardiac MRI segmentation with an ACDC challenge dataset / A. Janik et al. *Image Processing*, Online

Only, United States, 15–20 February 2021 / ed. by B. A. Landman, I. Išgum. 2021. URL: https://doi.org/10.1117/12.2582227 (date of access: 13.03.2025).

93. TorchEsegeta: Framework for Interpretability and Explainability of Image-Based Deep Learning Models / S. Chatterjee et al. *Applied Sciences*. 2022. Vol. 12, no. 4. P. 1834. URL: <u>https://doi.org/10.3390/app12041834</u> (date of access: 13.03.2025).

94. Post-Hoc Explainability of BI-RADS Descriptors in a Multi-Task Frameworkfor Breast Cancer Detection and Segmentation / M. Karimzadeh et al. 2023 IEEE33rd International Workshop on Machine Learning for Signal Processing (MLSP), Rome,Italy,7–20September2023.2023.URL:https://doi.org/10.1109/mlsp55844.2023.10286006(date of access: 13.03.2025).

95. Ellis C. A., Miller R. L., Calhoun V. D. Improving Explainability for Single-Channel EEG Deep Learning Classifiers via Interpretable Filters and Activation Analysis*. 2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), Istanbul, Turkiye, 5–8 December 2023. 2023. URL: https://doi.org/10.1109/bibm58861.2023.10385647 (date of access: 13.03.2025).

96. Explainability of deep neural networks for MRI analysis of brain tumors / R. A. Zeineldin et al. *International Journal of Computer Assisted Radiology and Surgery*. 2022. Vol. 17, no. 9. P. 1673–1683. URL: <u>https://doi.org/10.1007/s11548-022-02619-x</u> (date of access: 13.03.2025).

97. End-to-end learning with interpretation on electrohysterography data to predict preterm birth / A. M. Fischer et al. *Computers in Biology and Medicine*. 2023. P. 106846. URL: <u>https://doi.org/10.1016/j.compbiomed.2023.106846</u> (date of access: 13.03.2025).

98. Toward improving prediction accuracy and user-level explainability using deeplearning and knowledge graphs: A study on cassava disease / T. R. Chhetri et al. *Expert*SystemswithApplications.2023.P.120955.URL:https://doi.org/10.1016/j.eswa.2023.120955 (date of access: 13.03.2025).

99. Stevens A., De Smedt J., Peeperkorn J. Quantifying Explainability in Outcome-Oriented Predictive Process Monitoring. *Lecture Notes in Business Information Processing*. Cham, 2022. P. 194–206. URL: <u>https://doi.org/10.1007/978-3-030-98581-</u> <u>3_15</u> (date of access: 13.03.2025). 100. Benchmarking saliency methods for chest X-ray interpretation / A. Saporta et al. *Nature Machine Intelligence*. 2022. URL: <u>https://doi.org/10.1038/s42256-022-00536-x</u> (date of access: 13.03.2025).

101. Ranno N., Si D. Neural representations of cryo-EM maps and a graph-basedinterpretation.BMCBioinformatics.2022.Vol.23,S3.URL:https://doi.org/10.1186/s12859-022-04942-1(date of access: 13.03.2025).

102. Interpretation of Depression Detection Models via Feature Selection Methods / S. M. Alghowinem et al. *IEEE Transactions on Affective Computing*. 2020. P. 1. URL: <u>https://doi.org/10.1109/taffc.2020.3035535</u> (date of access: 13.03.2025).

103. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science*. Cham, 2015. P. 234–241. URL: <u>https://doi.org/10.1007/978-3-319-24574-4_28</u> (date of access: 13.03.2025).

104. Deep Residual Learning for Image Recognition / K. He et al. *CoRR*. 2015. Abs/1512.03385. URL: <u>http://arxiv.org/abs/1512.03385</u> (date of access: 13.03.2025).

105. Convolutional Neural Networks for Automated Built Infrastructure Detection in the Arctic Using Sub-Meter Spatial Resolution Satellite Imagery / E. Manos et al. *Remote Sensing*. 2022. Vol. 14, no. 11. P. 2719. URL: <u>https://doi.org/10.3390/rs14112719</u> (date of access: 13.03.2025).

106. Retinal Vascular Image Segmentation Using Improved UNet Based on Residual Module / K.-W. Huang et al. *Bioengineering*. 2023. Vol. 10, no. 6. P. 722. URL: <u>https://doi.org/10.3390/bioengineering10060722</u> (date of access: 13.03.2025).

107. Nisa S. Q., Ismail A. R. Dual U-Net with Resnet Encoder for Segmentation of Medical Images. *International Journal of Advanced Computer Science and Applications*. 2022. Vol. 13, no. 12. URL: <u>https://doi.org/10.14569/ijacsa.2022.0131265</u> (date of access: 13.03.2025).

108. CE-Net: Context Encoder Network for 2D Medical Image Segmentation / Z. Gu et al. *IEEE Transactions on Medical Imaging*. 2019. Vol. 38, no. 10. P. 2281–2292. URL: https://doi.org/10.1109/tmi.2019.2903562 (date of access: 13.03.2025).

109. Devi W., Roy S., Thongam K. Multi-Scale Dilated Fusion Network (MSDFN) for Automatic Instrument Segmentation. *Journal of Computer Science and Technology*

Studies. 2022. Vol. 4, no. 1. P. 66–72. URL: <u>https://doi.org/10.32996/jcsts.2022.4.1.7</u> (date of access: 13.03.2025).

110. Automatic Hierarchical Classification of Kelps Using Deep Residual Features / A. Mahmood et al. *Sensors*. 2020. Vol. 20, no. 2. P. 447. URL: <u>https://doi.org/10.3390/s20020447</u> (date of access: 13.03.2025).

111. A GPU-based residual network for medical image classification in smart medicine / Q. Zhang et al. *Information Sciences*. 2020. Vol. 536. P. 91–100. URL: <u>https://doi.org/10.1016/j.ins.2020.05.013</u> (date of access: 13.03.2025).

112. Wang M., Gong X. Metastatic Cancer Image Binary Classification Based on Resnet Model. 2020 IEEE 20th International Conference on Communication Technology (ICCT), Nanning, China, 28–31 October 2020. 2020. URL: https://doi.org/10.1109/icct50939.2020.9295797 (date of access: 13.03.2025).

113. Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer / D. Sarwinda et al. *Procedia Computer Science*. 2021. Vol. 179. P. 423–431. URL: <u>https://doi.org/10.1016/j.procs.2021.01.025</u> (date of access: 13.03.2025).

114. Pneumonia Image Classification Based on ResNet Model and Its Optimization / S. Li et al. 2023 8th International Conference on Intelligent Computing and Signal Processing (ICSP), Xi'an, China, 21–23 April 2023. 2023. URL: <u>https://doi.org/10.1109/icsp58490.2023.10248660</u> (date of access: 13.03.2025).

115. Recent advances in artificial intelligence for cardiac imaging / G. Yang et al. *Computerized Medical Imaging and Graphics*. 2021. Vol. 90. P. 101928. URL: <u>https://doi.org/10.1016/j.compmedimag.2021.101928</u> (date of access: 13.03.2025).

116. Current Concepts and Future Applications of Non-Invasive Functional and Anatomical Evaluation of Coronary Artery Disease / E. Oikonomou et al. *Life*. 2022. Vol. 12, no. 11. P. 1803. URL: <u>https://doi.org/10.3390/life12111803</u> (date of access: 13.03.2025).

117. Cardiac Imaging: Part 1, MR Pulse Sequences, Imaging Planes, and Basic Anatomy / D. T. Ginat et al. *American Journal of Roentgenology*. 2011. Vol. 197, no. 4. P. 808–815. URL: <u>https://doi.org/10.2214/ajr.10.7231</u> (date of access: 13.03.2025).

118. Wang X., Pu J. Recent Advances in Cardiac Magnetic Resonance for Imaging of Acute Myocardial Infarction (Small Methods 3/2024). *Small Methods*. 2024. Vol. 8, no.
3. URL: <u>https://doi.org/10.1002/smtd.202470014</u> (date of access: 13.03.2025).

119. McRobbie D. W., Moore E. A., Graves M. J. A Heart to Heart Discussion: CardiacMRI. *MRI from Picture to Proton. Cambridge*. P. 269–287. URL: <u>https://doi.org/10.1017/9781107706958.017</u> (date of access: 13.03.2025).

120. Role of CMR Mapping Techniques in Cardiac Hypertrophic Phenotype / A. Baggiano et al. *Diagnostics*. 2020. Vol. 10, no. 10. P. 770. URL: <u>https://doi.org/10.3390/diagnostics10100770</u> (date of access: 13.03.2025).

121. Echocardiographic findings in myocarditis / B. Pinamonti et al. *The American Journal of Cardiology*. 1988. Vol. 62, no. 4. P. 285–291. URL: <u>https://doi.org/10.1016/0002-9149(88)90226-3</u> (date of access: 13.03.2025).

122. Noninvasive detection of myocardial fibrosis in arrhythmogenic right ventricular cardiomyopathy using delayed-enhancement magnetic resonance imaging / H. Tandri et al. *Journal of the American College of Cardiology*. 2005. Vol. 45, no. 1. P. 98–103. URL: <u>https://doi.org/10.1016/j.jacc.2004.09.053</u> (date of access: 13.03.2025).

123. Wang Y., Jia H., Song J. Accurate Classification of Non-ischemicCardiomyopathy.CurrentCardiologyReports.2023.URL:https://doi.org/10.1007/s11886-023-01944-0 (date of access: 13.03.2025).

124. McKenna W. J., Maron B. J., Thiene G. Classification, Epidemiology, and Global Burden of Cardiomyopathies. *Circulation Research*. 2017. Vol. 121, no. 7. P. 722–730. URL: <u>https://doi.org/10.1161/circresaha.117.309711</u> (date of access: 13.03.2025).

125. Statistical validation of image segmentation quality based on a spatial overlap index1 / K. H. Zou et al. *Academic Radiology*. 2004. Vol. 11, no. 2. P. 178–189. URL: <u>https://doi.org/10.1016/s1076-6332(03)00671-8</u> (date of access: 13.03.2025).

126. Comparative Analysis using Various Performance Metrics in Imbalanced Data for Multi-class Text Classification / S. Riyanto et al. *International Journal of Advanced Computer Science and Applications*. 2023. Vol. 14, no. 6. URL: <u>https://doi.org/10.14569/ijacsa.2023.01406116</u> (date of access: 13.03.2025).

127. A. Clark and Contributors, Pillow: Python Imaging Library (PIL Fork), Python Software Foundation, 2010. Accessed November 22, 2024. <u>https://python-pillow.org</u> (date of access: 13.03.2025).

128. C. R. Harris, K. J. Millman, S. J. v. d. Walt, R. Gommers, P. Virtanen, D. Cournapeau, E. Wieser, J. Taylor, S. Berg, N. J. Smith, R. Kern, M. Picus, S. Hoyer, M. H. v. Kerkwijk and M. Brett, Array Programming with NumPy, *Nature*. 2020. Vol. 585, no. 7825. P. 357–362. URL: <u>https://doi.org/10.1038/s41586-020-2649-2</u> (date of access: 13.03.2025).

129. D. P. Kingma and J. Ba, Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. URL: <u>https://arxiv.org/abs/1412.6980</u> (date of access: 13.03.2025).

130. Mao A., Mohri M., Zhong Y. Cross-Entropy Loss Functions: Theoretical Analysis and Applications. URL: <u>https://arxiv.org/abs/2304.07288</u> (date of access: 13.03.2025).

131. Radiomics-Based Classification of Left Ventricular Non-compaction, Hypertrophic Cardiomyopathy, and Dilated Cardiomyopathy in Cardiovascular Magnetic Resonance / C. Izquierdo et al. *Frontiers in Cardiovascular Medicine*. 2021. Vol. 8. URL: <u>https://doi.org/10.3389/fcvm.2021.764312</u> (date of access: 13.03.2025).

132. Regional Assessment of Cardiac Left Ventricular Myocardial Function via MRI Statistical Features / M. Afshin et al. *IEEE Transactions on Medical Imaging*. 2014. Vol. 33, no. 2. P. 481–494. URL: <u>https://doi.org/10.1109/tmi.2013.2287793</u> (date of access: 13.02.2025).

133. Khened M., Kollerathu V. A., Krishnamurthi G. Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers. *Medical Image Analysis*. 2019. Vol. 51. P. 21–45. URL: <u>https://doi.org/10.1016/j.media.2018.10.004</u> (date of access: 13.03.2025).

134. Definitions for a common standard for 2D speckle tracking echocardiography: consensus document of the EACVI/ASE/Industry Task Force to standardize deformation imaging / J. U. Voigt et al. *European Heart Journal - Cardiovascular Imaging*. 2014. Vol. 16, no. 1. P. 1–11. URL: https://doi.org/10.1093/ehjci/jeu184 (date of access: 13.03.2025).

135. Standardized image interpretation and post-processing in cardiovascular magnetic resonance - 2020 update / J. Schulz-Menger et al. *Journal of Cardiovascular*

Magnetic Resonance. 2020. Vol. 22, no. 1. URL: <u>https://doi.org/10.1186/s12968-020-</u> 00610-6 (date of access: 13.03.2025).

136. Automatic Cardiac Disease Assessment on cine-MRI via Time-Series Segmentation and Domain Specific Features / F. Isensee et al. *Lecture Notes in Computer Science*. Cham, 2018. P. 120–129. URL: <u>https://doi.org/10.1007/978-3-319-75541-0_13</u> (date of access: 13.03.2025).

137. Automatic Segmentation of LV and RV in Cardiac MRI / Y. Jang et al. *Lecture Notes in Computer Science*. Cham, 2018. P. 161–169. URL: <u>https://doi.org/10.1007/978-3-</u> <u>319-75541-0_17</u> (date of access: 13.03.2025).

138. Khened M., Alex V., Krishnamurthi G. Densely Connected Fully Convolutional Network for Short-Axis Cardiac Cine MR Image Segmentation and Heart Diagnosis Using Random Forest. *Lecture Notes in Computer Science*. Cham, 2018. P. 140–151. URL: <u>https://doi.org/10.1007/978-3-319-75541-0_15</u> (date of access: 13.03.2025).

139. An Exploration of 2D and 3D Deep Learning Techniques for Cardiac MR Image Segmentation / C. F. Baumgartner et al. *Lecture Notes in Computer Science*. Cham, 2018. P. 111–119. URL: <u>https://doi.org/10.1007/978-3-319-75541-0_12</u> (date of access: 13.03.2025).

140. Khened M., Kollerathu V. A., Krishnamurthi G. Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers. *Medical Image Analysis*. 2019. Vol. 51. P. 21–45. URL: <u>https://doi.org/10.1016/j.media.2018.10.004</u> (date of access: 04.01.2025).

141. Zheng Q., Delingette H., Ayache N. Explainable cardiac pathology classification on cine MRI with motion characterization by semi-supervised learning of apparent flow. *Medical Image Analysis*. 2019. Vol. 56. P. 80–95. URL: <u>https://doi.org/10.1016/j.media.2019.06.001</u> (date of access: 04.01.2025).

142. Khened M., Kollerathu V. A., Krishnamurthi G. Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers. *Medical Image Analysis*. 2019. Vol. 51. P. 21–45. URL: <u>https://doi.org/10.1016/j.media.2018.10.004</u> (date of access: 13.03.2025).

143. 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: 13.03.2025).

144. Hua H., Pan N., Frangi A. F. Fully Automatic initialization and segmentation of Left and Right ventricles for Large-Scale cardiac MRI using a deeply supervised network and 3D-ASM. *Computer Methods and Programs in Biomedicine*. 2023. P. 107679. URL: <u>https://doi.org/10.1016/j.cmpb.2023.107679</u> (date of access: 13.03.2025).

145. Sander J., de Vos B. D., Išgum I. Automatic segmentation with detection of local segmentation failures in cardiac MRI. *Scientific Reports*. 2020. Vol. 10, no. 1. URL: <u>https://doi.org/10.1038/s41598-020-77733-4</u> (date of access: 13.03.2025).

146. Ammar A., Bouattane O., Youssfi M. Automatic cardiac cine MRIsegmentation and heart disease classification. Computerized Medical Imaging andGraphics.2021.Vol. 88.P. 101864.https://doi.org/10.1016/j.compmedimag.2021.101864(date of access: 13.03.2025).

147. A cascade approach for automatic segmentation of cardiac structures in short-axis cine-MR images using deep neural networks / I. F. S. da Silva et al. Expert SystemswithApplications.2022.Vol.197.P.116704.URL:https://doi.org/10.1016/j.eswa.2022.116704 (date of access: 13.03.2025).

ДОДАТОК А.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

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

1. Слободзян В. О., Бармак О. В. Метод класифікації МРТ-зображень серця за каскадними моделями глибокого навчання. Оптико-електронні-інформаційноенергетичні технології. 2024. Т. 48, Вип. 2. С. 104–113. (<u>https://doi.org/10.31649/1681-</u> 7893-2024-48-2-104-113).

2. Слободзян В. О., Бармак О. В. Метод сегментації МРТ серця на основі локалізації масок. *Вісник Хмельницького національного університету*. 2024. Т. 343, № 6 (1). С. 288–294. (https://doi.org/10.31891/2307-5732-2024-343-6-43).

3. Slobodzian V., Barmak O. Method for interpreting decisions made by deep learning models. *Computer systems and information technologies*. 2024. № 4. C. 150–156. (https://doi.org/10.31891/csit-2024-4-18).

Публікації, які засвідчують апробацію матеріалів дисертації:

4. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis / P. Radiuk et al. *5th International Conference on Informatics and Data-Driven Medicine, IDDM 2022* : Conference Proceedings, Lyon, 18–20 November 2022. 2022. P. 9–20. URL: <u>https://ceur-ws.org/Vol-3302/paper1.pdf</u>. (*iндексована в наукометричній базі Scopus*).

5. Myocardium Segmentation using Two-Step Deep Learning with Smoothed Masks by Gaussian Blur / V. Slobodzian et al. *6th International Conference on Informatics and Data-Driven Medicine, IDDM 2023*: Conference Proceedings, Bratislava, 17–19 November 2022. 2023. P. 77–91. URL: <u>https://ceur-ws.org/Vol-3609/paper7.pdf</u>. *(індексована в наукометричній базі Scopus).*

6. Multi-Stage Segmentation and Cascade Classification Methods for Improving Cardiac MRI Analysis / V. Slobodzian et al. *Information Technology and Implementation* (*IT&I-2024*) : Conference Proceedings, 20–21 November 2024. Kyiv, 2024. URL: <u>https://arxiv.org/pdf/2412.09386</u>.

Свідоцтво про реєстрацію авторського права на твір:

7. А. с. 133517 Україна. Комп'ютерна програма «Класифікація МРТ на наявність патологій з подальшою інтерпретацією результатів» / В. О. Слободзян, О. В. Бармак, П. М. Радюк. 2025.

ДОДАТОК Б. АКТИ ВПРОВАДЖЕННЯ

ДОВІДКА

про впровадження результатів дисертаційної роботи Слободзяна Віталія Олександровича «Методи виявлення патологій серця за MPT зображенням засобами пояснювального штучного інтелекту»

У процесі виробничої діяльності ТОВ «АЙ ТІ ХУТ» м.Хмельницького знайшли застосування такі результати дисертаційної роботи Слободзяна Віталія Олександровича «Методи виявлення патологій серця за МРТ зображенням засобами пояснювального штучного інтелекту»:

- метод багатоступеневої сегментації МРТ зображень для виявлення точних контурів структур серця;

- метод каскадної класифікації для виявлення патологій серця за MPTзображеннями з інтегрованою інформацію про структури серця;

- метод візуального подання та пояснення результатів отриманих за глибоким навчанням, який забезпечує зручний інтерфейс для інтерпретування виявлених патологій серця;

У ТОВ «АЙ ТІ ХУТ» зазначені результати використовуються в процесі розроблення промислового програмного забезпечення для створення застосувань у модулях для класифікації медичних зображень на малих обчислювальних пристроях та для додавання елементів до архітектури інформаційних систем.

ВО Директора Анаголій ДАНЬКОВ



Лікувально-діагностичний центр «Сіліцея-СІТІ+» м.Хмельницький проспект Миру, 84/1 +38(096)083-03-03 e-mail: <u>silicea.city@gmail.com</u>

ДОВІДКА

про застосування результатів наукових досліджень

за темою дисертаційної роботи

Слободзяна Віталія Олександровича

Результати дисертаційної роботи Слободзяна Віталія Олександровича за темою «Методи виявлення патологій серця за МРТ зображенням засобами пояснювального штучного інтелекту»;, а саме інформаційна технологія виявлення патологій серця за МРТ зображеннями була використана у вигляді експериментального рішення в роботі медичного центру «Сіліцея Сіті+» для цифрового діагностування

патологій серця на МРТ зображеннях з допомогою засобів комп'ютерної діагностики. Застосування здійснювалося у вигляді веб-орієнтованої інформаційної системи.

Директор МЦ «Сіліцея Сіті+»

Aynein M. Solacri, + (1) BOUTIN

"ЗАТВЕРДЖУЮ" Проректор з наукової роботи Хмельницького національного університету д.т.н., професор Синюк О.М. ... 2024 p.

АКТ

про впровадження в навчальний процес результатів досліджень аспіранта Слободзяна Віталія Олександровича за темою дослідження «Методи виявлення патологій серця за МРТ зображенням засобами пояснювального штучного інтелекту»

Результати дисертаційної роботи Слободзяна В.О., а саме, інтелектуальні методи обробки медичних зображень (зображення МРТ), використовуються в навчальному процесі при викладанні дисциплін бакалаврського рівня «Інтелектуальний аналіз даних», «Методи та системи штучного інтелекту», та магістерського рівня «Методи, засоби та алгоритми в задачах обчислювального інтелекту та комп'ютерного зору», виконанні кваліфікаційних робіт бакалаврів та магістрів спеціальності "Комп'ютерні науки".

Акт обговорений і схвалений на засіданні кафедри комп'ютерних наук (протокол № 4 від 27 листопада 2024 р.).

Зав. каф. комп'ютерних наук, д.т.н., професор Секретар кафедри КН, ст.викладач

CM.

О.В. Бармак

Т.К. Скрипник

УКРАЇНА Міністерство освіти і науки України ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ Ідентифікаційний код 02071234 29016 ауп. інститутська, 11. м.Хмельницький "_______20___р. № Зав. кафедрою д.т.н, професору Олександру БАРМАКУ

Довідка

Doulle

Аспірант кафедри комп'ютерних наук Слободзян Віталій Олександрович брав участь з оплатою праці у виконанні держбюджетної теми № 2Б-2024 «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (номер державної реєстрації 0124U000980)

Проректор з науковот роботи

CBITH

Олег СИНЮК

ДОДАТОК В. АВТОРСЬКЕ СВІДОЦТВО



ДОДАТОК Г. ВИХІДНИЙ КОД

Вихідний код, використаний у дослідженні, доступний у репозиторії GitHub: <u>https://github.com/vitalii-slobodzian/cardiac-mri-analysis</u> (дата звернення: 13.03.2025).

На наступному рисунку наведено знімок екрана репозиторію.

scardiac-mri-analysis (Public)		🖈 Pin	O Unwatch	1 • % Fork 0 •	☆ Star 0 ▼
🐉 develop 👻 🐉 2 Branches 🛇 0 Tags	Q Go to file	t Add file 🝷	<> Code -	About	\$
🗳 vitalii-slobodzian Add segmentation learner, helper and training code ea82be2 · last month			🕑 6 Commits	No description, website, or topics provide	
classification/helpers	Add initial project structure and base im	2 months ago	-/- Activity		
segmentation	Add segmentation learner, helper and t	last month	☆ 0 stars		
visualization	Add initial project structure and base im	2 months ago	2 months ago v 0 forks		
🗅 .gitignore	Add gitignore		2 months ago	Releases No releases published Create a new release	
C README.md	Update README.md	2 months ago			
README			Ø		
The code to reproduce the re publicly available at here upo	esults from all experiment	s will be made		Packages No packages published Publish your first package	

Головна сторінка репозиторію

Структура репозиторію наступна:

– модулі для сегментації (*segmentation*). Містить код для сегментації МРТзображень, зокрема код для підготовки вхідних даних, навчання моделей та код проведення експериментів для валідації методу сегментації;

– модулі класифікації зображень (*classification*). Містить код для класифікації МРТ-зображень з інтегрованими даними про сегментацію, зокрема код для підготовки вхідних даних, навчання моделей та код проведення експериментів для валідації методу сегментації;

модулі для візуалізації та аналізу результатів (visualization). Забезпечує засоби для графічного відображення та інтерпретації результатів сегментації і класифікації. Включає функції візуалізації та створення графіків.