
СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

УДК 004.92

В.О. СЛОБОДЗЯН, О.В. БАРМАК

МЕТОД КЛАСИФІКАЦІЇ МРТ ЗОБРАЖЕНЬ СЕРЦЯ ЗА КАСКАДНИМИ МОДЕЛЯМИ ГЛИБОКОГО НАВЧАННЯ

*Хмельницький національний університет,
21016, вул. Інституцька, 11, м. Хмельницький, Україна
e-mail: Vitalii.slobodzin@gmail.com*

Анотація. МРТ-дослідження серця є ключовим методом для діагностики серцево-судинних захворювань. У статті запропоновано вдосконалення методу класифікації серцевих захворювань за допомогою каскаду бінарних класифікаторів на основі глибокого навчання. Запропонована модель спрямована на точне розпізнавання таких захворювань, як гіпертрофічна кардіоміопатія, інфаркт міокарда та дилатаційна кардіоміопатія. Використання каскаду дозволяє покращити ефективність класифікації, поділяючи загальну задачу на менші підзадачі, кожна з яких орієнтована на виявлення конкретної патології. Таким чином, модель може краще фокусуватися на характерних особливостях захворювань, що мінімізує ризики сплутування між подібними патологіями та підвищує загальну точність. Метод досягає середньої точності 97,2%, що перевершує результати відомих підходів. Окремі класифікатори показують точність до 100% при виявленні гіпертрофічної кардіоміопатії та аномалій правого шлуночка, в той час як для інфаркту міокарда та дилатаційної кардіоміопатії точність становить 90%. Ці результати свідчать про потенціал методу для використання в клінічній практиці, але також підкреслюють необхідність подальшого вдосконалення при роботі з менш типовими або складними випадками.

Ключові слова: МРТ серця, патологія серця, глибоке навчання, класифікація, каскадна модель

Abstract. Cardiac MRI is a key method for diagnosing cardiovascular diseases, offering detailed insights into heart structure and function. However, the complexity of cardiac pathologies requires advanced methods for accurate diagnosis. This paper proposes an improved method for classifying heart diseases using a cascade of binary classifiers based on deep learning. By leveraging this cascade approach, the system is able to break down the classification process into multiple stages, each focusing on a specific disease, which enhances the overall accuracy and reliability of the diagnosis. The proposed model is designed to accurately identify a range of heart diseases, including hypertrophic cardiomyopathy, myocardial infarction, dilated cardiomyopathy, and right ventricular abnormalities. The use of a cascade of classifiers enables a more efficient classification process by dividing the task into smaller, manageable subtasks. Each classifier in the cascade is specialized in detecting a particular pathology, allowing the model to focus on the unique characteristics of each disease. This approach reduces the risk of misclassification between similar conditions and improves the overall accuracy of the model. The method achieves an impressive average accuracy of 97.2%, which surpasses the results of known approaches. In particular, individual classifiers demonstrate up to 100% accuracy in detecting hypertrophic cardiomyopathy and right ventricular abnormalities, showcasing the precision of the model in these areas. For myocardial infarction and dilated cardiomyopathy, the method achieves an accuracy of 90%, which, although slightly lower, still represents a high level of diagnostic performance. These results highlight the significant potential of this method for clinical application, offering a more reliable tool for the diagnosis of complex heart conditions. However, the findings also emphasize the necessity of further development, particularly in cases involving less typical or more challenging pathologies. Future work will focus on refining the model and expanding its applicability across a broader range of clinical scenarios to ensure its robustness and effectiveness in real-world settings.

Keywords: cardiac MRI, heart pathology, deep learning, classification, cascade model

DOI: 10.31649/1681-7893-2024-48-2-104-113

СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

ВСТУП

Серцево-судинні захворювання (ССЗ) є однією з основних причин смертності в усьому світі, що підкреслює важливість вдосконалення методів діагностики та лікування [1]. Оцінка стану серця через сучасні методи візуалізації є критично важливою для своєчасного виявлення патологій. Магнітно-резонансна томографія (МРТ) серця є провідним методом завдяки своїй високій точності та здатності надавати детальні зображення структури серця та функціонування шлуночків. Однак, для ефективного використання МРТ важливо мати потужні інструменти для автоматичного аналізу даних, особливо для класифікації патологій серця.

МРТ серця дозволяє діагностувати різні захворювання, але складність серцевої анатомії і можливі артефакти ускладнюють процес аналізу. Для підвищення точності діагностики необхідні автоматизовані системи, здатні класифікувати серцеві захворювання на основі аналізу зображень. В цьому контексті штучний інтелект (ШІ) відкриває нові можливості для автоматизації класифікації даних МРТ, що дозволяє скоротити час діагностики та підвищити точність результатів [2].

Штучні нейронні мережі, зокрема глибоке навчання, показали високу ефективність у медичній діагностиці, дозволяючи розробляти моделі для автоматизованого аналізу медичних зображень. Однак, для успішної інтеграції ШІ в медичну практику є ряд викликів, зокрема необхідність великих наборів даних для навчання моделей та забезпечення конфіденційності пацієнтів.

Метою цього дослідження є вдосконалення процесу класифікації серцевих захворювань за МРТ-зображеннями засобами глибокого навчання. Запропонований підхід використовує каскадне застосування декількох моделей глибокого навчання.

Основним внеском дослідження є запропонований новий метод каскадної класифікації, який дозволяє підвищити точність визначення патологій серця.

1. ОГЛЯД ЛІТЕРАТУРИ

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 простіших задач, вони поступаються глибинним моделям, особливо при роботі з великими наборами даних. [3]

Згорткові нейронні мережі (CNN) відіграють ключову роль у класифікації медичних зображень, завдяки здатності автоматично витягувати складні ознаки з вхідних даних. Архітектури ResNet [4] і DenseNet [5] є одними з найпопулярніших для вирішення задач сегментації та класифікації патологій. Наприклад, модель DenseNet продемонструвала високу ефективність у класифікації зображень пухлин, особливо при використанні невеликих патчів із великих цифрових патологічних зображень [6].

Методи штучного інтелекту відзначаються високою точністю та можливістю адаптації через перенавчання на нових даних, що дозволяє створювати моделі, які змінюються та поліпшуються разом із 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 [7]. Крім того, існує питання довіри до рішень, що приймаються штучним інтелектом. З огляду на це, все більшу популярність набувають концепції, які інтегрують людину в процес ухвалення рішень, як-от "human-in-the-loop" та "human-centric", з метою підвищення прозорості та довіри до результатів роботи систем [8, 9].

Метод [10] 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: дилатаційна кардіоміопатія (DCM), гіпертрофічна кардіоміопатія (HCM), інфаркт міокарда (MINF), аномалія правого шлуночка (RVA) і нормальні випадки. 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 [11] зосереджується на класифікації захворювань за даними кіно-МРТ, використовуючи комбінацію моделей сегментації та класифікації. Метод інтегрує сегментацію серцевих структур (лівий шлуночок, правий шлуночок і міокард лівого шлуночка) з класифікацією захворювань у

СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

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 сегментованих областей, включаючи традиційні метрики форми, такі як об'єм шлуночків і товщина міокарда, а також динамічні ознаки, як-от зміни об'єму з часом. Для класифікації використовується набір ручно створених ознак, отриманих із цих сегментацій, для навчання ансамблю багатосарових перцептронів (MLP) і класифікатора випадкових лісів. Ця модель прогнозує п'ять патологічних категорій (ARV, HCM, MINF, DCM, NOR), як і в попередньому підході. 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 [12] використовує поєднання глибокого навчання та ансамблевих класифікаторів для автоматизації діагностики серцевих захворювань за даними кіно-MPT. Метод інтегрує сегментацію серцевих структур і класифікацію захворювань у повністю автоматизовану систему. Автори використовують архітектуру повністю згортової нейронної мережі на основі DenseNets, розроблену для сегментації ключових серцевих структур, таких як лівий шлуночок, правий шлуночок і 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, багатосарові 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. Модель класифікації досягла точності 100%. Ансамбль класифікаторів додає складності й 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.

Отже, за результатами наведеного аналізу, основною метою дослідження є підвищення точності класифікації шляхом розробки нового методу аналізу MPT зображень серця. Для досягнення поставленої мети, потрібно вирішити наступні задачі:

- декомпонувати загальне завдання класифікації патологій серця на відповідні завдання класифікації з меншою кількістю класів патологій для уникнення нерівномірної кількості зразків у класах;
- запропонувати метод класифікації, який використовує каскадний підхід.

2. ВИКЛАД ОСНОВНОГО МАТЕРІАЛУ

Анатомічною особливістю визначення патологій серця за MPT зображеннями є врахування наступних основних характерних рис: щільність та однорідність тканин серця, об'єми шлуночків та їх форма в динаміці, товщина та форма міокарду в динаміці. Виходячи з наведених особливостей, для визначення патологій засобами глибокого навчання, пропонується врахувати анатомічні параметри серця шляхом певної модифікації вхідного зображення. Тобто, запропонований метод буде використовувати результати сегментації отримані за наведеним раніше методом, що, на думку авторів, дозволить покращити результати класифікації [13,14,15].

Окрім зазначеного, метод використовує одночасно MPT 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.

У методі запропоновано подати на вхід моделі глибокого навчання модифіковане MPT-зображення. Модифікація полягає у наступному:

Оскільки діагностично значущими є анатомічні особливості серця, такі як розміри шлуночків, товщина міокарду та інші геометричні параметри, для класифікації доцільно використовувати маски сегментації. Однак для деяких патологій необхідно враховувати неоднорідність тканин, що робить виключне використання масок недостатнім. Для вирішення цієї проблеми маски сегментації та MPT-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 подати різні анатомічні частини у вигляді окремих кольорових шарів, що забезпечує чіткіше 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

СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

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 неоднорідностями тканин, що потенційно покращує результати класифікації патологій.

На рис. 1 зображено множину зображень, які будуть подаватись на вхід моделі глибокого навчання.




Рисунок 1 – Візуалізації вхідних даних.

- Перший рядок - зображення з систолічної фази, другий рядок – зображення з діастолічної фази.
- Колонки – зрізи вздовж короткої осі.
- Червоним кольором позначені сегменти правого шлуночку, синім кольором лівого шлуночку, та зеленим кольором сегмент міокарду

На рис. 2 зображена схема застосування чотирьох класифікаторів для визначення патології.

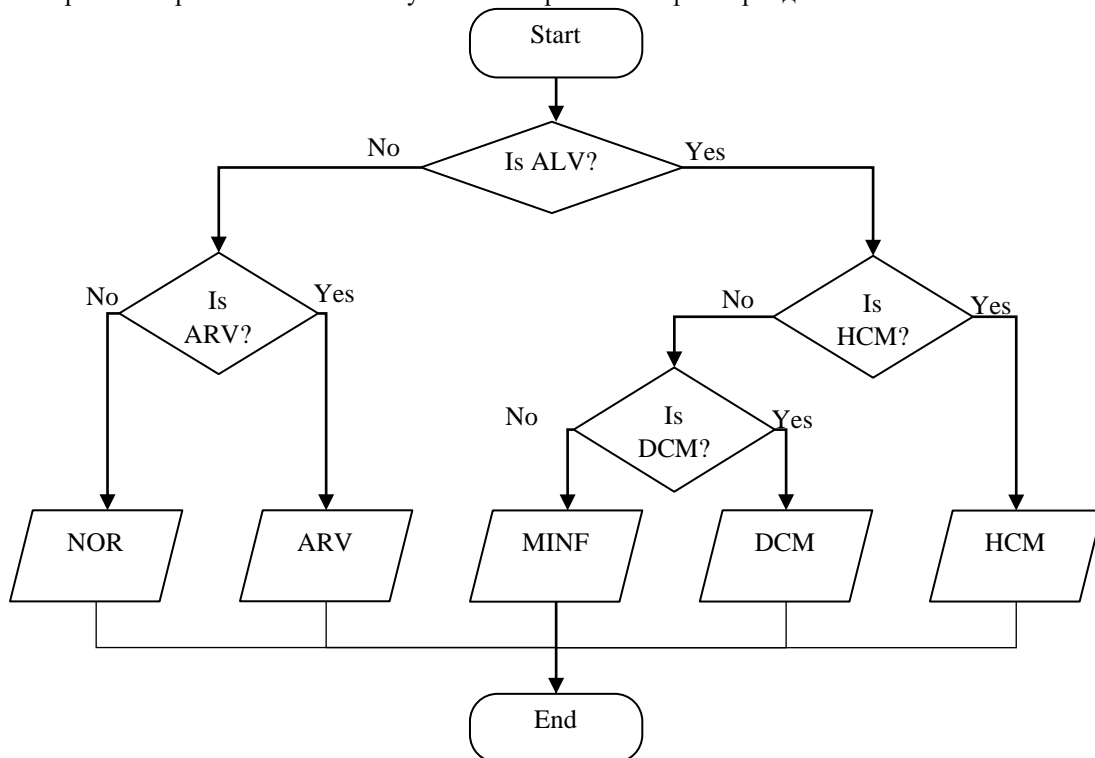


Рисунок 2 – Алгоритм каскадного застосування бінарних класифікаторів

Виходячи з проблеми характерної для датасетів медичного спрямування (нерівномірність зразків у різних класах), у методі пропонується використати каскадну модель класифікації. Обґрунтуванням використання каскадного підходу є те, що при використанні невеликих наборів даних важко 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), зосередитися на конкретних особливостях двох класів, що призведе до збільшення точності класифікації [16,17,18].

Загальна схема методу зображена на рис.3.

**СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ
З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ**

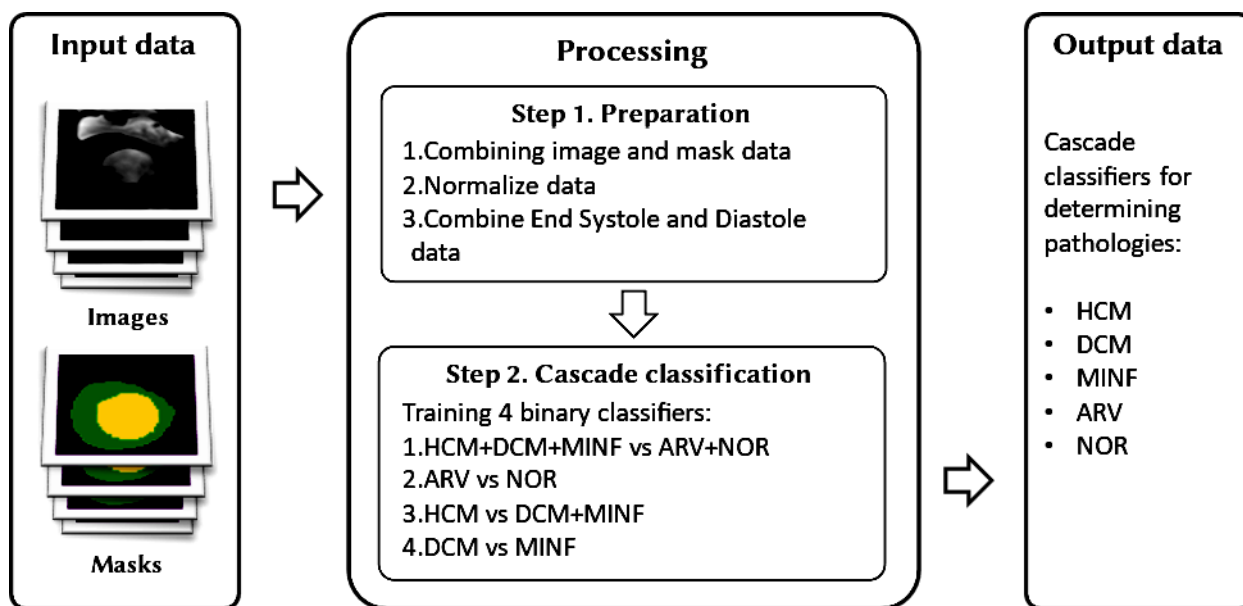


Рисунок 3 – Загальна схема методу класифікації патологій серця за МРТ зображеннями

Запропоновано наступний каскад класифікаторів [20,21,22].

Класифікатор 1. Перший класифікатор відокремлює патології лівого шлуночку та решту можливих варіантів, включаючи патології правого шлуночка і нормальний стан пацієнта. Це дозволяє моделі глибокого навчання ігнорувати деталі кожної патології, та зосередитися лише на загальних ознаках для виявлення наявності або відсутності патології лівого шлуночку.

Класифікатор 2. Другий класифікатор розділяє виявлені *Класифікатором 1* класи (аномальний правий шлуночок та нормальний стан) на два підкласи. Відділення цих класів від патології лівого шлуночка дозволяє моделі глибокого навчання краще зосередитися на особливостях патології правого шлуночку та краще відділити їх від нормального стану.

Класифікатор 3. Третій класифікатор проводить розділення, виявлених на першому кроці, патології лівого шлуночка на два підкласи: гіпертрофічну кардіоміопатію та решту патології лівого шлуночку. Модель глибокого навчання зосереджується на специфічних ознаках гіпертрофічної кардіоміопатії, дозволяючи краще ідентифікувати цей тип патології.

Класифікатор 4. Четвертий класифікатор розділяє решту патології лівого шлуночку на патології попереднього інфаркту міокарда та дилатаційну кардіоміопатію. 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.

У якості класифікаторів запропоновано використовувати моделі глибокого навчання у вигляді згорткової нейронної мережі (CNN), адаптованої для задачі бінарної класифікації. Архітектура нейронної мережі схематично зображена на рис.4.

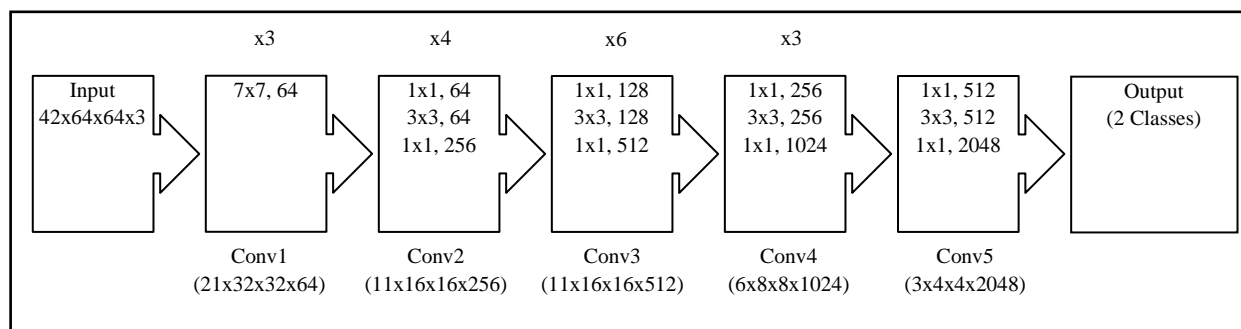


Рисунок 4 – Архітектура моделі глибокого навчання для класифікаторів.

СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

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.

Далі наведемо основні кроки методу.

Вхідною інформацією методу є зображення з датасету, модифіковані наведеним вище чином, які містять зображення для кожного пацієнта в моменти діастолічної та систолічної фаз кардіоциклу.

Step 1. Підготовка МРТ-зображень. Всі МРТ-зображення обрізаються, щоб залишити лише область з необхідними сегментами (знайденими з допомогою першого методу) та приводяться до єдиного розміру. Дані маски та зображення об'єднуються (кожен сегмент серця відповідно до маски подається в окремому каналі, як описано вище).

Step 2. Навчання каскаду з 4 класифікаторів. Кожен класифікатор навчається окремо з використанням однакового підходу. Процес навчання починається зі створення та компіляції моделі за архітектурою, що була описана вище. Використовується оптимізатор Adam і функцію втрат «categorical crossentropy». Дані розділяються на навчальну та валідаційну вибірки, зберігаючи пропорції класів. Під час навчання застосовується механізм ранньої зупинки для запобігання перенавчанню, що зупиняє навчання, якщо валідаційні втрати не покращуються.

Вихідною інформацією методу є навчений каскад класифікаторів, які дозволяють визначити наступні патології:

1. Аномальний правий шлуночок (abnormal right ventricle) (ARV)
2. Гіпертрофічна кардіоміопатія (hypertrophic cardiomyopathy) (HCM)
3. Попередній інфаркт міокарда (previous myocardial infarction) (MINF)
4. Дилатаційна кардіоміопатія (dilated cardiomyopathy) (DCM)
5. Нормальний стан (NOR).

Для навчання та тестування всіх моделей з першого та другого етапів використовується набір даних Automated Cardiac Diagnosis Challenge (ACDC) [13]. 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. Для навчальної та тестової вибірки використовуються попередньо сформовані тестові та навчальні набори відповідно до оригінальної роботи авторів набору даних.

3. ОЦІНКА ОТРИМАНИХ РЕЗУЛЬТАТІВ

Запропонований метод класифікації було оцінено за допомогою кількох показників, таких як загальна точність (Accuracy), Precision, Recall та F1-score. У кожному з чотирьох кроків класифікації було використано метрики, що дозволяють оцінити виявлення та відокремлення різних патологій серця. На рис.5 зображена матриця помилок (Confusion Matrix) для кожного кроку класифікації, яка демонструє рівень правильних, хибно позитивних та хибно негативних результатів класифікацій.

СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

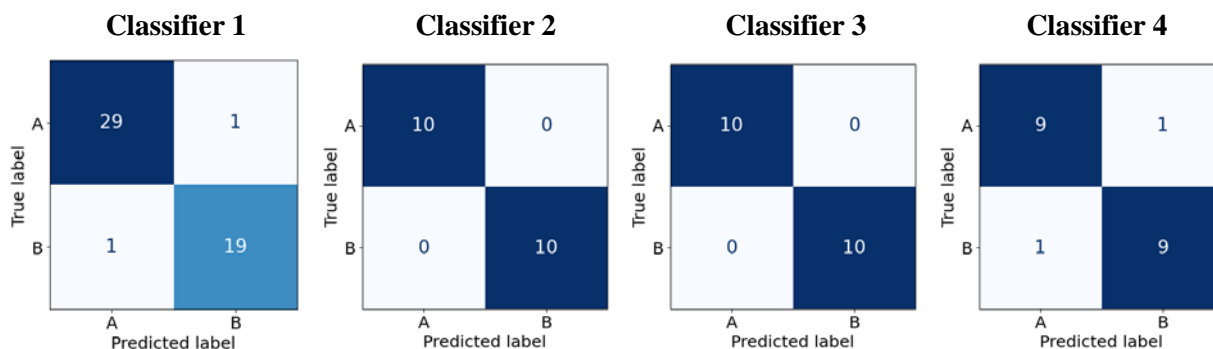


Рисунок 5 – Confusion matrix для кожного кроку класифікації.

Таблиці 1-4 демонструють ефективність запропонованого методу на кожному з кроків. Перший крок показав високу точність 0.96 для відокремлення патологій лівого шлуночка від решти варіантів, а другий крок досяг максимальної точності 1.0 для класифікації між нормальним станом та аномаліями правого шлуночка. Третій крок також досяг максимальної точності 1.0 для гіпертрофічної кардіоміопатії та решти патологій лівого шлуночка, а четвертий крок, де розрізнялись попередній інфаркт міокарда та дилатаційна кардіоміопатія, показав точність на рівні 0.90.

Таблиця 1

Classification evaluation metrics for classifier 1

	Precision	Recall	F1-Score	Accuracy
NOR+ARV	0.95	0.95	0.95	0.96
MINF+HCM+DCM	0.97	0.97	0.97	

2

Classification evaluation metrics for classifier 2

	Precision	Recall	F1-Score	Accuracy
NOR	1.0	1.0	1.0	1.0
ARV	1.0	1.0	1.0	

Таблиця 3

Classification evaluation metrics for classifier 3

	Precision	Recall	F1-Score	Accuracy
HCM	1.0	1.0	1.0	1.0
MINF+DCM	1.0	1.0	1.0	

Таблиця 4

Classification evaluation metrics for classifier 4

	Precision	Recall	F1-Score	Accuracy
MINF	0.90	0.90	0.90	0.90
DCM	0.90	0.90	0.90	

Більшість авторів у своїх публікаціях використовують загальну точність класифікації для порівняння з іншими авторами. Для каскадної класифікації пропонується використовувати наступний підхід до розрахунку усередненої точності всієї моделі: розрахувати точність кожного кроку окремо, розрахувати точність класифікації кожного класу окремо та середнє арифметичне точності для всіх класів вважати за загальну усереднену точність методу класифікації. Для наведених розрахунків використовуються наступні формалізми:

$$A_{\text{NOR,ARV}} = \frac{A_{\text{Classifier 1}} + A_{\text{Classifier 2}}}{2} \quad (1)$$

СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

$$A_{HCM} = \frac{A_{Classifier\ 1} + A_{Classifier\ 3}}{2} \quad (2)$$

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

$$A = \frac{A_{NOR} + A_{ARV} + A_{HCM} + A_{MINF} + A_{DCM}}{5} \quad (4)$$

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

Порівняння загальної точності методу з результатами робіт інших авторів представлено в таблиці 5.

Таблиця 5

Comparison of classification accuracy with other methods

Method	Accuracy
Ours	97%
Mahendra et. al. [12]	100%
Zheng et. al. [10]	94%
Isensee et. al. [11]	92%

На рис.6 зображені криві ROC (Receiver Operating Characteristic) для кожного з чотирьох кроків класифікації, відображаючи співвідношення між чутливістю (True Positive Rate) і специфічністю (False Positive Rate). Площа під кривою (AUC) є важливим показником загальної якості моделі, оскільки вона показує, наскільки добре модель здатна розрізняти класи між собою.

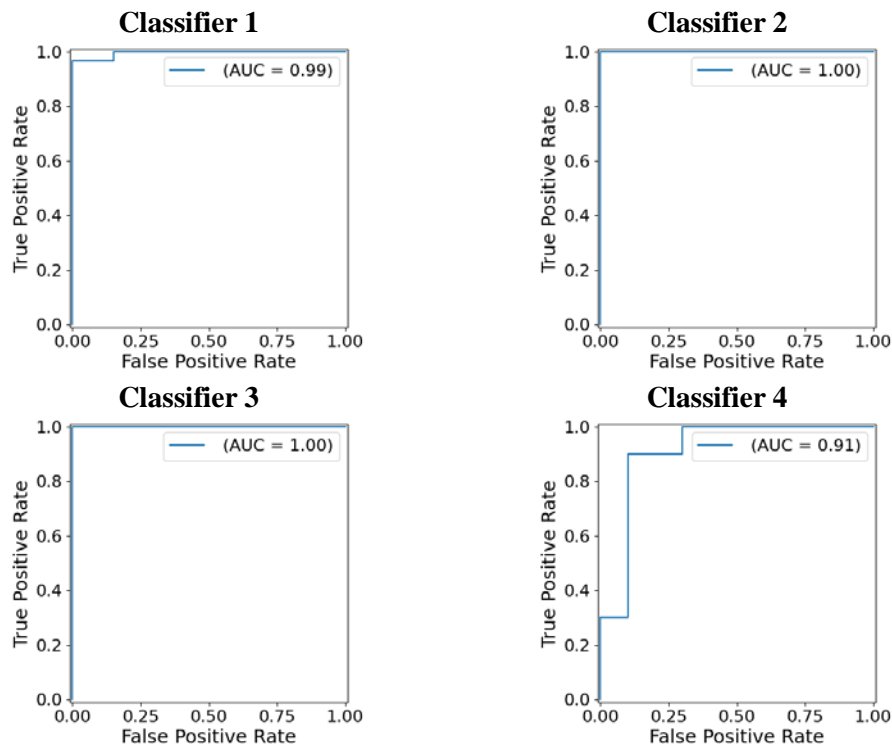


Рисунок 6 – AUC для кожного кроку класифікації.

СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

ВИСНОВКИ

У дослідженні наведено новий підхід до класифікації МРТ-зображень серця, який дозволив виявляти такі захворювання серця, як гіпертрофічна кардіоміопатія, інфаркт міокарда та дилатаційна кардіоміопатія, підвищивши точність за допомогою використання каскаду класифікаторів за моделями глибокого навчання,

Ефективність методів оцінювалася за допомогою таких метрик як Accuracy, Precision, Recall та F1-Score. Класифікація показала високу точність (96%) для патології лівого шлуночка, 100% для аномального правого шлуночку та нормального стану, 100% для гіпертрофічної кардіоміопатії та 90% для диференціації інфаркту міокарда від дилатаційної кардіоміопатії. Запропонований метод перевершив відомі методи в точності класифікації. Незважаючи на ці багатообіцяючі результати, метод має обмеження, особливо під час обробки зображень низької якості або роботи зі складними патологіями, де точність класифікації може знизитися.

Майбутня робота буде зосереджена на перевірці підходу в різних протоколах візуалізації, щоб забезпечити його узагальнення. Крім того, наступний етап дослідження включатиме розробку нових методів інтерпретації результатів, спрямованих на те, щоб зробити метод більш прозорим і надійним у клінічних умовах.

СПИСОК ЛІТЕРАТУРИ / REFERENCES

1. Invisible numbers: the true extent of noncommunicable diseases and what to do about them. Geneva: World Health Organization; 2022. Licence: CC BY-NC-SA 3.0 IGO.
2. Radiuk P., Barmak O., Manziuk E. and Krak I. (2024) Explainable Deep Learning: A Visual Analytics Approach with Transition Matrices, *Mathematics*, 12.7 1024. doi:10.3390/math12071024.
3. Zhong Z., Zheng M., Mai H., Zhao J. and Liu X. (2020). Cancer image classification based on DenseNet model.", In *Journal of physics: conference series*, Vol. 1651, no. 1, p. 012143. IOP Publishing,
4. He K., Zhang X., Ren S. and Sun J. (2016). Deep Residual Learning for Image Recognition, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 770-778, doi: 10.1109/CVPR.2016.90.
5. Huang G., Liu Z., Maaten L.v.d. and Weinberger K.Q. (2018). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, p. 4700-4708): doi: 10.48550/arXiv.1608.06993.
6. Zhong Z., Zheng M., Mai H., Zhao J. and Liu X. (2020). Cancer image classification based on DenseNet model., In *Journal of physics: conference series*, vol. 1651, no. 1, p. 012143. IOP Publishing.
7. Rehman K.A. (2022). Facial Emotion Recognition Using Conventional Machine Learning and Deep Learning Methods: Current Achievements, Analysis and Remaining Challenges. *Information* 13, 268: doi: 10.3390/info13060268.
8. Hu S., Liao Z., Liu Z. and Xia Y. (2024). Towards Clinician-Preferred Segmentation: Leveraging Human-in-the-Loop for Test Time Adaptation in Medical Image Segmentation. *arXiv preprint arXiv:2405.08270*.
9. Zheng Q., Delingette H. and Ayache N. (2019): Explainable cardiac pathology classification on cine MRI with motion characterization by semi-supervised learning of apparent flow., *Medical image analysis*, 56, p. 80-95.
10. Isensee F., Jaeger P. F., Full P. M., Wolf I., Engelhardt S. and Maier-Hein K. H. (2017). Automatic cardiac disease assessment on cine-MRI via time-series segmentation and domain specific features", 8th International Workshop, STACOM 2017, Held in Conjunction with MICCAI 2017, Quebec City, Canada, September 10-14, Revised Selected Papers 8, p. 120-129.
11. Mahendra K., Kollerathu V. A. and Krishnamurthi G. (2019). Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers, *Medical image analysis*, 51, 21-45.
12. Bernard O., Lalande A., Zoti C. and Cervenansky F., et al. (2018). Deep Learning Techniques for Automatic MRI Cardiac Multi-structures Segmentation and Diagnosis: Is the Problem Solved ? in *IEEE Transactions on Medical Imaging*, Vol. 37, no. 11, p. 2514-2525: doi: 10.1109/TMI.2018.2837502.
13. Davila A., Colan J. and Hasegawa Y. (2024). Comparison of fine-tuning strategies for transfer learning in medical image classification.", *Image and Vision Computing*, 146: 105012.
14. Wójcik Waldemar, Smolarz Andrzej (2017). *Information Technology in Medical Diagnostics*, July 11,

СИСТЕМИ ТЕХНІЧНОГО ЗОРУ І ШТУЧНОГО ІНТЕЛЕКТУ З ОБРОБКОЮ ТА РОЗПІЗНАВАННЯМ ЗОБРАЖЕНЬ

- 2017 by CRC Press, 210 Pages.
15. Highly linear Microelectronic Sensors Signal Converters Based on Push-Pull Amplifier Circuits / edited by Waldemar Wojcik and Sergii Pavlov, Monograph, (2022) NR 181, Lublin, Comitet Inzynierii Srodowiska PAN, 283 Pages. ISBN 978-83-63714-80-2
 16. Pavlov Sergii, Avrunin Oleg, Hrushko Oleksandr, and etc. (2021). System of three-dimensional human face images formation for plastic and reconstructive medicine // Teaching and subjects on bio-medical engineering Approaches and experiences from the BIOART-project Peter Arras and David Luengo (Eds.), Corresponding authors, Peter Arras and David Luengo. Printed by Acco cv, Leuven (Belgium). - 22 P. ISBN: 978-94-641-4245-7.
 17. Pavlov S.V., Avrunin O.G., etc. (2019). Intellectual technologies in medical diagnosis, treatment and rehabilitation: monograph / [S. In edited by S. Pavlov, O. Avrunin. - Vinnytsia: PP "TD "Edelweiss and K", 260 p. ISBN 978-617-7237-59-3.
 18. Romanyuk, O., Zavalniuk, Y., Pavlov, S., etc. (2023). New surface reflectance model with the combination of two cubic functions usage, Informatyka, Automatyka, Pomiarzy w Gospodarce i Ochronie Srodowiska, , 13(3), pp. 101–10
 19. Kukharchuk, Vasyl V., Sergii V. Pavlov, Volodymyr S. Holodiuk, Valery E. Kryvonosov, Krzysztof Skorupski, Assel Mussabekova, and Gaini Karnakova. (2022). "Information Conversion in Measuring Channels with Optoelectronic Sensors" *Sensors* 22, no. 1: 271. <https://doi.org/10.3390/s22010271>.
 20. Vasyl V. Kukharchuk, Sergii V. Pavlov, Samoil Sh. Katsyv, and etc. (2021). Transient analysis in 1st order electrical circuits in violation of commutation laws”, *Przegląd elektrotechniczny*, ISSN 0033-2097, R. 97 NR 9/2021, p. 26-29, doi:10.15199/48.2021.09.05.
 21. Pavlov S.V, Petruk V.G., Kolesnik P.F. (2007). Photoplethysmographic technologies of the cardiovascular control: monography, Vinnitsa: Universum-Vinnitsa, 254 p.
 22. Wójcik W, Mezhiievskia I, Pavlov SV, Lewandowski T, Vlasenko OV, Maslovskiy V, Volosovych O, Kobylanska I, Moskovchuk O, Ovcharuk V, et al. (2023). Medical Fuzzy-Expert System for Assessment of the Degree of Anatomical Lesion of Coronary Arteries. *International Journal of Environmental Research and Public Health*. 20(2):979. <https://doi.org/10.3390/ijerph20020979>.

Надійшла до редакції 5.10.2024 р.

СЛОБОДЗЯН ВІТАЛІЙ ОЛЕКСАНДРОВИЧ — аспірант кафедри комп'ютерних наук, Хмельницький національний університет, [e-mail: vitalii.slobodzian@gmail.com](mailto:vitalii.slobodzian@gmail.com)

БАРМАК ОЛЕКСАНДР ВОЛОДИМИРОВИЧ — доктор технічних наук, професор, завідувач кафедри комп'ютерних наук, Хмельницький національний університет, [e-mail: barmako@khmnu.edu.ua](mailto:barmako@khmnu.edu.ua)

V.O. Slobodzian, O.V. BARMAK
**METHOD OF CARDIAC MRT OF CLASSIFICATION
BASED ON DEEP LEARNING CASCADE MODELS**
Khmelnitskyi National University