


КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА


на тему Метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця


Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань

Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності

Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконала: студентка групи КН-21-1  Оксана ГЛОБЧАСТА
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: док.філ., ст. викл. каф. КН  Павло РАДЮК
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ


Нормоконтроль: к.т.н., доц. каф. КН  Руслан БАГРІЙ
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

До захисту допускаю:
зав. кафедри КН, д.т.н., професор  Олександр БАРМАК
Підпис Ім'я, ПРІЗВИЩЕ

20 06 2025 р.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
Факультет інформаційних технологій
Кафедра комп'ютерних наук
Освітній ступінь бакалавр
Галузь знань 12 – Інформаційні технології
Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ
Завідувач кафедри комп'ютерних наук


(підпис)
д.т.н., професор Олександр БАРМАК

«10» 02 2025 року

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА

1. Тема кваліфікаційної роботи бакалавра: «Метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця»

2. Завдання видано студентці Оксані Глобчастій
(Ім'я, прізвище)

3. Керівник роботи старший викладач кафедри КН Павло РАДЮК
(посада, ім'я, прізвище)

4. Затверджено наказом університету від «07» 02 2025 р. № 23

5. Дата видачі завдання студенту: «10» 02 2025 р.

6. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Мета кваліфікаційної роботи бакалавра – підвищення точності цифрової сегментації ділянок серця на зображеннях МРТ на основі інтеграції експертних знань в модель глибокого навчання. Мета роботи має бути досягнута внаслідок виконання таких завдань: провести аналітичний огляд методів, способів та підходів до інтеграції експертних знань в модель глибокого навчання для задачі сегментування зображень МРТ; спроектувати метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця; виконати програмну реалізацію методу інтеграції експертних знань в модель глибокого навчання у вигляді вебсервіса; здійснити експериментальне тестування створеного вебсервіса за МРТ зображеннями серця.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

№	Назва етапів (розділів) кваліфікаційної роботи бакалавра	Термін виконання	Примітка
1	Вибір напряму дослідження та узгодження тематики кваліфікаційної роботи бакалавра з керівником, складання календарного графіка виконання	січень 2025	виконано
2	Ознайомлення з предметною областю, формулювання мети і завдань дослідження, визначення об'єкта та предмета дослідження	лютий 2025	виконано
3	Проектування метода розв'язання завдання, загальної архітектури програмного забезпечення, інтерфейсу користувача, вибір засобів реалізації програмного забезпечення	березень 2025	виконано
4	Створення та тестування програмного забезпечення, дослідження точності, висновки з виконаної роботи	квітень 2025	виконано
5	Написання пояснювальної записки, урахування зауважень керівника, оформлення згідно з вимогами	травень 2025	виконано
6	Розроблення презентаційних матеріалів та попередній захист кваліфікаційної роботи	травень 2025	виконано
7	Отримання відгуку керівника, рецензії, перевірка на плагіат, нормоконтроль	червень 2025	виконано
8	Підготовка до захисту та захист кваліфікаційної роботи	червень 2025	виконано

Виконавець: студентка групи КН-21-1

Група виконавця


Підпис

Оксана ГЛОБЧАСТА

Ім'я, ПРІЗВИЩЕ

Керівник: док.філ., ст.викл. каф.КН

Науковий ступінь, посада


Підпис

Павло РАДЮК

Ім'я, ПРІЗВИЩЕ

Анотація

Тема кваліфікаційної роботи бакалавра: «Метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця»

Виконавець кваліфікаційної роботи бакалавра: студентка групи КН-21-1 Оксана ГЛОБЧАСТА

Керівник кваліфікаційної роботи бакалавра: доктор філософії, старший викладач кафедри КН Павло РАДЮК

Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
51	11	4	40	2

Мета кваліфікаційної роботи бакалавра – підвищення точності цифрової сегментації ділянок серця на зображеннях МРТ через проєктування метода інтеграції експертних знань в модель глибокого навчання.

У рамках роботи досліджено способи інтеграції медичних експертних знань, як от анатомічні та морфологічні правила до нейромережевої моделі за архітектурою U-Net. Спроектований метод полягає у модифікації функції втрат через додавання спеціальних штрафів за порушення експертних правил. Програмна реалізація методу виконана у вигляді вебсервіса з використанням мови програмування Python та фреймворку TensorFlow. Вебсервіс створено користувацьким з інтерфейсом на базі платформи Gradio.

Ключові слова: магнітно-резонансна томографія, сегментування зображень серця, глибоке навчання, інтеграція знань, експертні правила.

Виконавець: студент групи КН-21-1
Група виконавця


Підпис

Оксана ГЛОБЧАСТА
Ім'я, ПРІЗВИЩЕ

Зміст

Перелік скорочень	4
Вступ.....	5
Розділ 1 Характеристика процесу сегментування зображень МРТ серця засобами глибокого навчання.....	7
1.1 Аналіз галузі оброблення зображень МРТ серця	7
1.2 Огляд способів та методів штучного інтелекту для оброблення та сегментації МРТ-зображень	10
1.3 Аналіз програмних рішень для оброблення зображень МРТ серця	12
1.4 Мета та завдання до кваліфікаційної роботи бакалавра	16
Розділ 2 Проєктування методу інтеграції експертних знань у модель глибокого навчання для сегментування зображень МРТ серця	17
2.1 Основна ідея та загальний підхід до проєктування методу.....	17
2.1.1 Ідея методу.....	17
2.1.2 Основні етапи методу	17
2.2 Опис архітектури нейромережевої моделі	19
2.3 Функціональна структура інформаційної системи для програмної реалізації методу.....	23
2.4 Проєктна архітектура системи та взаємозв'язок компонентів.....	26
2.5 Інформаційна структура системи	29
2.6 Підготовка вхідних даних для системи	30
2.7 Особливості використання спеціалізованих програмних компонентів	31
2.8 Висновки до розділу 2	33
Розділ 3 Експериментальне дослідження методу інтеграції експертних знань та його програмної реалізації	34
3.1 Опис програмної реалізації методу інтеграції експертних знань у вигляді вебсервіса	34
3.1.1 Опис користувацького інтерфейсу вебсервіса.....	34
3.1.2 Особливості реалізації програмних складових вебсервіса.....	36
3.1.3 Тестування вебсервіса та вимоги до розгортання	38
3.2 Результати досліджень	41

	3
3.3 Висновки до розділу 3	44
Загальні висновки.....	45
Перелік посилань.....	47
Додатки	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
AUC	Area Under the Curve
CA	Cardiac Amyloidosis
CMR	Cardiovascular magnetic resonance
CNN	Convolutional Neural Network
DAFNet	Disentangle-and-Fuse Network
DL	Deep Learning
FiLM	Feature-wise Linear Modulation
LGE	Late Gadolinium Enhancement
ML	Machine Learning
ROC	Receiver Operating Characteristic curve
STN	Spatial Transformer Network
БД	База даних
ЕЗ	Експертні знання
ІС	Інформаційна система
ІТ	Інформаційні технології
КН	Комп'ютерні науки
КРБ	Кваліфікаційна робота бакалавра
МРТ	Магнітно-резонансна томографія
НМ	Нейронна мережа
ПП	Програмний продукт
ССЗ	Серцево-судинні захворювання

Вступ

Кваліфікаційна робота бакалавра присвячена підвищенню точності цифрової сегментації ділянок серця на зображеннях магнітно-резонансної томографії (МРТ) через проектування метода інтеграції експертних знань в модель глибокого навчання.

Актуальність. МРТ серця є одним із провідних методів візуалізації, що дає можливість детально оцінити анатомію та функціональний стан серцево-судинної системи. Однак, попри високу інформативність, одним із найскладніших етапів оброблення зображень МРТ є сегментація серцевих структур – виділення анатомічно значущих областей, таких як лівий та правий шлуночки, міокард, передсердя тощо. Цей процес ускладнюється через значну індивідуальну варіативність анатомії пацієнтів, зміни форми структур при патологічних процесах, а також наявність неоднорідного контрасту.

З огляду на це, актуальним та перспективним є створення методу, здатного поєднувати гнучкість класичних підходів до сегментування зображень серця з результативністю глибокого навчання. Відповідно у цій роботі пропонується метод інтеграції експертних знань (наприклад, у вигляді правил або морфологічних критеріїв) у модель глибокого навчання для покращення процесу сегментування зображень МРТ серця.

Об'єкт дослідження – процес сегментування зображень МРТ серця засобами глибокого навчання.

Предмет дослідження – методи, засоби та підходи до інтеграції експертних знань в модель глибокого навчання та оброблення медичних зображень МРТ серця.

Мета кваліфікаційної роботи бакалавра – підвищення точності цифрової сегментації ділянок серця на зображеннях МРТ на основі інтеграції експертних знань в модель глибокого навчання.

Завдання кваліфікаційної роботи бакалавра – провести аналітичний огляд методів, способів та підходів до інтеграції експертних знань в модель

глибокого навчання для задачі сегментування зображень МРТ; спроектувати метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця; виконати програмну реалізацію методу інтеграції експертних знань в модель глибокого навчання у вигляді вебсервіса; здійснити експериментальне тестування створеного вебсервіса за МРТ зображеннями серця.

Розділ 1 Характеристика процесу сегментування зображень МРТ серця засобами глибокого навчання

1.1 Аналіз галузі оброблення зображень МРТ серця

Серцево-судинні захворювання – це група патологій серця та судин, до якої належать такі хвороби як: ішемічна хвороба серця (зокрема стенокардія та інфаркт міокарда), артеріальна гіпертензія, порушення мозкового кровообігу (інсульт), ревматичні ураження серця та інші порушення. Згідно зі статистикою, дані захворювання стали однією з основних причин смертності у світі. Більше 80% смертей від серцево-судинних хвороб спричинені саме інфарктами [1].

Їхній перебіг часто починається малопомітно та прогресує з часом. На початкових етапах пацієнти можуть скаржитися на втому, задишку, набряки гомілок, затримку рідини та інші неспецифічні симптоми. До найбільш поширених форм ССЗ належать ішемічна хвороба серця, що включена в список неінфекційних захворювань, аритмії, кардіоміопатії, вроджені вади серця, мітральна регургітація та стенокардія [2].

Рівень смертності від ССЗ в останні роки знизився в усіх регіонах, попри те, що в кінці 90-х років і до 2008 смертність мала досить високі показники, як серед чоловіків, так і серед жінок. Наприклад, у регіоні з високим рівнем доходу спостерігався найшвидший середній темп зниження з 1990 по 2019 рік. Найповільніші темпи зниження чисельності обох статей спостерігалися в регіонах Південно-Східної Азії, Південної Азії, Східної Азії та Океанії та Африки на південь від Сахари. У цих регіонах майже не спостерігалось покращення смертності чоловіків від ССЗ. Рівень смертності в регіоні Африки на південь від Сахари був у 1,2 рази вищим, ніж у регіоні з високим рівнем доходу, у 1990 році, тоді як до 2019 року цей розрив зріс до рівня смертності в 2,1 раза вищого в країнах Африки на південь від Сахари, ніж у регіоні з високим доходом. Регіон з високим рівнем доходу мав найнижчий загальний рівень смертності від серцево-судинних захворювань, що вказує на кращі діагностичні можливості спеціалістів

(це як рівень знань та обізнаності лікарів, так і якість обладнання для точної та швидкої діагностики) [3].




Рисунок 1.1 – Регіональні тенденції стандартизованого за віком рівня смертності від серцево-судинних захворювань (на 100 000 осіб), 1990-2019 рр. [3]

Для діагностики цих станів широко застосовуються клінічні методи, зокрема лабораторні аналізи, електрокардіографія (ЕКГ) та методи медичної візуалізації. Електрокардіографія – це метод, що дає можливість записувати електричні імпульси, які виникають у серцевому м’язі під час його роботи, за допомогою електродів, розміщених на поверхні тіла. Отримана графічна крива називається ЕКГ і відображає зміни електричного потенціалу в серці під час його збудження [4].

Серед інструментальних методів обстеження все більшого значення набуває МРТ серця, яка використовується для діагностики, контролю перебігу захворювання, планування лікування та прогнозування результатів. Проте аналіз МРТ-даних є складним завданням через велику кількість зображень, обмежену контрастність і складність анатомічних структур [5].

МРТ – це сучасний неінвазивний (процедури, які не проникають у тіло яким-небудь прямим способом [6]) метод медичного діагностування, що дає змогу отримувати високоякісні зображення внутрішніх органів, тканин і систем організму. Завдяки цьому МРТ дає можливість точно візуалізувати структуру м'яких тканин, головного і спинного мозку, суглобів, серця та внутрішніх органів без використання іонізуючого випромінювання [7].

У МРТ використовуються потужні магніти, які створюють сильне магнітне поле, що змушує протони в тілі вирівнюватися з цим полем. Коли через пацієнта пропускається радіочастотний струм, протони стимулюються та виходять з рівноваги, напружуючись проти сили тяжіння магнітного поля. Коли радіочастотне поле вимикається, датчики МРТ здатні виявляти енергію, що вивільняється, коли протони переорієнтовуються з магнітним полем. Час, необхідний для переорієнтації протонів з магнітним полем, а також кількість вивільненої енергії змінюється залежно від навколишнього середовища та хімічної природи молекул. Лікарі можуть розрізняти різні типи тканин на основі цих магнітних властивостей [8].

Завдяки високій контрастності зображень, особливо між різними типами м'яких тканин, МРТ широко застосовується не лише для діагностики, а й для динамічного спостереження за хронічними захворюваннями. Особливо важливим є використання МРТ серця при виявленні ішемічної хвороби, кардіоміопатій, вроджених вад серця та при плануванні хірургічного втручання.

Згідно з даними Європейського товариства кардіологів, МРТ серця є найточнішим методом для опису інфаркту міокарда як у гострій, так і в хронічній фазі, а також для оцінки життєздатності міокарда та прогнозування функціонального відновлення [9].

Однією з головних переваг МРТ є її безпечність – процедура є безболісною та не несе променевого навантаження на пацієнта, тому може застосовуватися навіть у педіатричній практиці та під час вагітності (за наявності показань та без використання контрасту в першому триместрі) [10].

Для автоматизації та підвищення якості аналізу МРТ-зображень, також залучається і штучний інтелект. Наприклад, компанія Aidoc пропонує рішення для передбачення ризику інсульту, що дає можливість своєчасно розпочати лікування та уникнути серйозних наслідків [11].

Отже, застосування інформаційних технологій, зокрема штучного інтелекту, значно покращить діагностику, що в свою чергу може вплинути на рівень смертності в позитивному плані.

1.2 Огляд способів та методів штучного інтелекту для оброблення та сегментування МРТ-зображень

Основні напрямки застосування штучного інтелекту в кардіоваскулярній МРТ:

1. Планування обстеження: ШІ може оптимізувати планування МРТ-обстежень, автоматично визначаючи найкращі параметри сканування для кожного пацієнта. Це дає можливість зменшити час обстеження та підвищити якість отриманих зображень.

2. Прискорена реконструкція зображень: Використання глибоких нейронних мереж, зокрема Convolutional Neural Network. CNN – це тип штучної нейронної мережі, призначений для оброблення зображень і виявлення на них просторових ознак, таких як контури, текстури та об'єкти [12]. Її використання дає можливість швидко реконструювати високоякісні зображення з меншої кількості даних, що в свою чергу зменшує час сканування та покращує комфорт пацієнта.

3. Автоматизована сегментація та аналіз: Автоматизована сегментація та аналіз. ШІ може автоматично сегментувати серцеві структури, такі як шлуночки та передсердя, на МРТ-зображеннях. Це забезпечує точні та відтворювані вимірювання, зменшуючи залежність від ручної оброблення та підвищуючи точність діагностики.

4. Прогнозування та клінічне рішення

Прогнозування та клінічне рішення. Моделі машинного навчання можуть аналізувати МРТ-дані разом з клінічною інформацією для прогнозування результатів лікування, ризику ускладнень та підтримки прийняття клінічних рішень [13].

Для реалізації програмних рішень для будь-якого з напрямків є різні варіанти нейромереж та методів. До прикладу, для планувальника можна розробити системи на основі Machine Learning та Reinforcement Learning.

ML-методи, навчають моделі виявляти закономірності в даних для виконання завдань, таких як класифікація, регресія або кластеризація. Модель навчається на фіксованому наборі даних (заздалегідь підготовлених прикладах), і потім застосовується до нових прикладів [14].

RL-метод працює інакшим чином. Агент взаємодіє з середовищем, вчиться на основі винагороди (або покарання) і приймає рішення послідовно в часі. Немає фіксованого набору даних. Модель навчається через проб і помилок, отримуючи зворотний зв'язок у вигляді нагороди [15].

Порівняння обох методів представлено в таблиці 1.1.

Таблиця 1.1 – Порівняння деяких властивостей ML та RL методів

Характеристика	Machine Learning (ML)	Reinforcement Learning (RL)
Навчання на прикладах	Так (потрібен навчальний набір даних)	Ні (навчання через взаємодію)
Тип завдань	Класифікація, регресія	Прийняття послідовних рішень
Зворотний зв'язок	У вигляді правильних відповідей	У вигляді нагород/штрафів
Приклад у медичній сфері	Діагностика по знімках	Автоматичне налаштування параметрів МРТ

Для прогнозування ж, як варіант, можна використати рекурентну нейронну мережу, або ж Recurrent Neural Networks.

RNN – це тип штучної нейронної мережі, призначений для оброблення послідовних або часових даних. На відміну від звичайних (feedforward) мереж, RNN має зворотні зв'язки, що дає можливість їй зберігати інформацію про попередні стани та використовувати її для оброблення поточних входів. Ця властивість робить RNN особливо ефективною для завдань, де важливий контекст, наприклад, у розпізнаванні мови, машинному перекладі, генерації тексту та аналізі часових рядів. RNN працює через передачі інформації від одного кроку до наступного, використовуючи внутрішню пам'ять для збереження даних про попередні входи [16]. Саме застосування рекурентних нейромереж для аналізу клінічних даних та описів, здатне допомогти лікарям та спеціалістам з прогнозуванням ризиків та виставленням діагнозів.

У сукупності, впровадження ШІ, зокрема нейромереж, що аналізуватимуть уже готові дані, може пришвидшити швидкість діагностики за допомогою прогнозів, в результаті значно покращити дослідження МРТ. А успішність застосування НМ в цьому напрямку медицини показує велику перспективність даного напрямку для штучного інтелекту.

1.3 Аналіз програмних рішень для оброблення зображень МРТ серця

Для спрощення роботи з даними МРТ-досліджень уже існують різні варіації реалізацій методів ШІ та розроблені нейронні мережі. Тому, для кращого розуміння, можна розглянути кілька прикладів, уже готових та протестованих програмних рішень.

У статті [17] дослідники вивчали точність застосування глибокого навчання (Deep Learning, DL) для автоматизованої діагностики серцевого амілоїдозу (СА) за допомогою магнітно-резонансної томографії серця (CMR), зокрема зображень із відстроченим контрастуванням (LGE).

У дослідженні взяли участь 206 пацієнтів із підозрою на СА. Для аналізу було використано зображення з CMR у кількох площинах (2-камерна, 4-камерна

та коротка вісь). Дослідники розробили три незалежні згорткові нейронні мережі, які автоматично класифікували наявність або відсутність амілоїдозу.

Для порівняння також була створена модель машинного навчання (ML), яка використовувала вручну витягнуті характеристики зображень. На основі порівняння кривих AUC, CNN та метод на основі ML показали подібну діагностичну точність з різницею 0,39.

Для контексту, ROC-крива (Receiver Operating Characteristic curve) – це графік, який показує залежність між чутливістю (True Positive Rate) і хибнопозитивною частотою (False Positive Rate) класифікатора при зміні порогу прийняття рішення.

ROC-крива показує компроміс між чутливістю і специфічністю при різних порогах. AUC (Area Under the Curve) – зручне узагальнення якості моделі у вигляді одного числа (варіюється від 0 до 1). Причому, чим більше AUC, тим краща здатність моделі розрізняти класи [18].

Результати показали високу точність DL-моделей: точність становила 88%, а площа під ROC-кривою (AUC) сягала 0,982. Для порівняння, AUC моделі машинного навчання становила 0,952. Крім того, DL-система була значно швидшою – обробка одного дослідження займала лише 0,7-1.4 секунди, що є значною перевагою у клінічному застосуванні.

Отже, дослідження продемонструвало, що моделі глибокого навчання можуть точно й швидко діагностувати серцевий амілоїдоз на основі зображень CMR, досягаючи результатів, які порівнюювані з висновками досвідчених лікарів.

Ще один яскравий приклад – модель DAFNet [19]. У даній статті розглядається використання штучного інтелекту для аналізу мульти-модальних зображень серця – зокрема таких, як cine-MRI (Cine Magnetic Resonance Imaging – різновид МРТ, який забезпечує рухомі зображення внутрішніх органів, зокрема серця, дозволяючи лікарю спостерігати їх рух у реальному часі) [20] та LGE-MRI (Late Gadolinium Enhancement MRI – тип МРТ із застосуванням гадолінію як контрасту для виявлення запалень, фіброзу або рубців у серці) [21].

Модель DAFNet (Disentangle-and-Fuse Network) являє собою 2D сегментаційну архітектуру, яка працює в умовах мульти-модального та напівконтрольованого навчання. Її мета – розділити зображення на анатомічні фактори (структура серця) та модальні фактори (характеристики, притаманні певному типу візуалізації). Це дає можливість моделі краще інтерпретувати й комбінувати інформацію з різних МРТ-джерел. У структурі DAFNet використовується U-Net-подібний енкодер-декодер, який витягує анатомічні риси із зображень. U-Net використовується переважно для задач сегментації зображень, особливо у медичній візуалізації) [22].

Для просторового вирівнювання анатомічної інформації з різних модальностей застосовується Spatial Transformer Network – це підмережа, яка адаптивно коригує форми структур, вирівнюючи їх до спільної системи координат, диференційованого модуля, який можна інтегрувати в згорткові нейронні мережі для досягнення просторової інваріантності [23].

STN дає можливість мережі самостійно навчатися просторовим трансформаціям (таким як масштабування, обертання, зсув), адаптуючи вхідні дані до канонічної форми. Це підвищує точність класифікації та робить модель стійкішою до варіацій у вхідних зображеннях.

Архітектура STN складається з трьох компонентів:

- локалізаційна мережа: аналізує вхідне зображення та визначає параметри трансформації;
- генератор сітки: використовує ці параметри для створення сітки координат, які відповідають бажаній трансформації;
- семплер: застосовує цю сітку до вхідного зображення, використовуючи білінійну інтерполяцію, щоб отримати трансформоване зображення.

STN особливо корисний у задачах комп'ютерного зору, де об'єкти можуть з'являтися в різних положеннях або масштабах, наприклад, у розпізнаванні рукописних цифр чи об'єктів на зображеннях з шумами та спотвореннями (рисунок 1.2), що в свою чергу ідеально підходить для роботи із МРТ-зображеннями [24].

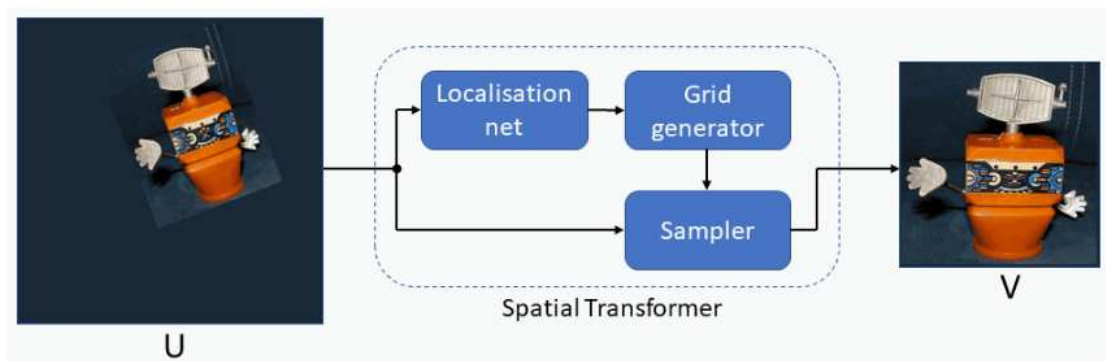


Рисунок 1.2 – Модуль просторового трансформатора перетворює вхідні дані в канонічну позу, тим самим спрощуючи розпізнавання в наступних шарах [24]

Після вирівнювання анатомічні та модальні ознаки об'єднуються – це етап "злиття" (fusion), який дає можливість зберегти важливу інформацію з обох джерел. Для декодування і генерації сегментації використовується FiLM-модуль (Feature-wise Linear Modulation) – це метод у глибокому навчанні, який дає можливість змінювати активації нейронної мережі залежно від зовнішньої інформації. Його суть полягає у тому, щоб масштабувати та зсувати кожен канал ознак (features) за формулою:

$$FiLM(x) = x \cdot \gamma(z_1) + \beta(z_2), \quad (1.1)$$

де x – вхідна ознака, z_1 – вхідним кондиціонуванням, z_2 – залежні масштабування та зсув векторів, а γ і β – параметри, що залежать від зовнішнього сигналу (наприклад, тексту, класу або експертних знань) [25].

Завдяки такій архітектурі DAFNet досягає високої точності сегментації навіть при обмеженій кількості розмічених зображень, що особливо актуально для медичних задач. Це робить її перспективною для клінічного використання.

З огляду на досліджені статті та аналіз програмних рішень з результатами їх тестування, основний уклон ШІ, в даній предметній області, на роботу із зображеннями, що є головними даними в МРТ-діагностиці. Навчання нейромереж для аналізу самих зображень дуже важливий аспект. Однак разом із цим, паралельно розвиваються і методи для кращої роботи обладнання, тобто методи для прогнозування картинки та їх чистка від зайвих шумів, націлені на підвищення якості МРТ.

1.4 Мета та завдання до кваліфікаційної роботи бакалавра

Отже, огляд сучасних рішень для оброблення зображень МРТ серця, таких як CNN, RNN та RL, показав різноманіття інструментів для реалізації дієвих діагностичних систем. Аналіз прикладів програмних рішень, зокрема DL-моделей для діагностики серцевого амілоїдозу, підтверджує практичну цінність і переваги неймереж у клінічному застосуванні – як за точністю, так і за швидкістю оброблення результатів. Така автоматизація може суттєво зменшити навантаження на лікарів та підвищити точність прийняття клінічних рішень. Як наслідок, поєднання можливостей МРТ та інтелектуальних алгоритмів на основі неймереж дає можливість отримати дієвий інструмент для підвищення точності цифрової сегментації ділянок серця на МРТ-зображеннях.

Отже, метою кваліфікаційної роботи бакалавра є підвищення точності цифрової сегментації ділянок серця на зображеннях МРТ на основі інтеграції експертних знань в модель глибокого навчання.

Досягнення мети роботи полягає у виконанні таких завдань.

1. Провести аналітичний огляд методів, способів та підходів до інтеграції експертних знань в модель глибокого навчання для задачі сегментування зображень МРТ.

2. Спроекувати метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця.

3. Виконати програмну реалізацію методу інтеграції експертних знань в модель глибокого навчання у вигляді вебсервіса.

4. Здійснити експериментальне тестування створеного вебсервіса за МРТ зображеннями серця.

Розділ 2 Проєктування методу інтеграції експертних знань у модель глибокого навчання для сегментування зображень МРТ серця

2.1 Основна ідея та загальний підхід до проєктування методу

2.1.1 Ідея методу

У сучасній медичній діагностиці, зокрема в МРТ, критично важливою є точність виділення (сегментації) анатомічних структур. Оскільки якість діагностики безпосередньо залежить від точності та швидкості аналізу зображень, виникає необхідність залучення інтелектуальних алгоритмів. Одним із перспективних напрямів є використання глибокого навчання, зокрема згорткових нейронних мереж, з додатковою інтеграцією експертних знань (ЕЗ) – структурованої інформації, отриманої від медичних фахівців.

Основна ідея проєктованого методу інтеграції експертних знань у модель глибокого навчання для сегментації зображень МРТ серця базується на комбінуванні двох підходів: автоматичного сегментування за допомогою моделі U-Net та постоброблення результатів із застосуванням правил, сформульованих на основі експертного досвіду.

Такий підхід є особливо корисним у випадках складних патологій або неоднозначних результатів, де повністю автоматичні рішення можуть бути недостатньо точними. Крім того, він забезпечує гнучкість, адаптивність та пояснюваність результатів – важливі властивості для систем, що впроваджуються у медичну практику.

2.1.2 Основні етапи методу

Для легшого розуміння, які саме етапи проходитиме метод, нижче представлено схему роботи методу інтеграції експертних знань у модель глибокого навчання (рисунок 2.1):

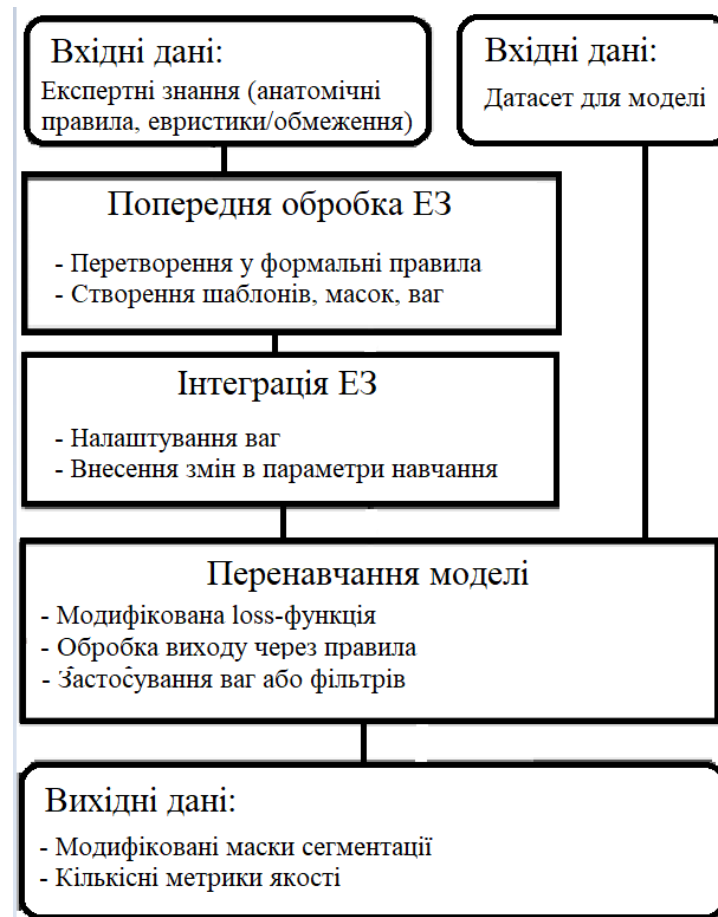


Рисунок 2.1 – Схема роботи методу інтеграції експертних знань у модель глибокого навчання для сегментування зображень МРТ серця

Нижче, представлено опис кожного етапу:

1. Попередня обробка експертних знань.

На цьому етапі має здійснюватися формалізація знань експертів, які можуть бути представлені у вигляді:

- анатомічних правил (наприклад, шлуночки мають певні просторові пропорції);
- функціональних обмежень (наприклад, взаємне розташування структур серця);
- евристик або логічних правил (наприклад, межі серцевих камер не повинні перетинатися).

Знання можуть бути представлені у вигляді логічних виразів, мап вагомості, масок чи шаблонів.

2. Інтеграція експертних знань у модель.

Центральною частиною методу є вбудовування експертної інформації в процес навчання або прогнозування. Це може реалізовуватись за допомогою:

- модифікації функції втрат (loss function), з додаванням штрафних компонентів за порушення анатомічних чи логічних правил;
- введення просторових або контекстуальних вагових коефіцієнтів до результату сегментації;
- накладання експертної маски як додаткового каналу входу або після обробки;
- корекції передбачень моделі на основі логічних обмежень або фільтрації результатів.

3. Модифікація та перенавчання моделі.

Вже навчена модель може бути донавчена (fine-tuned) з урахуванням нових функцій втрат або додаткових входів, які враховують експертні знання. Також можливе часткове заморожування початкових шарів і адаптація лише високорівневих компонентів моделі.

4. Аналіз та оцінка результатів.

Після інтеграції експертної інформації результати сегментації аналізуються за класичними метриками (Dice, IoU), а також за спеціальними критеріями, що відображають відповідність анатомічним нормам. Або ж проводиться порівняння результатів до і після інтеграції ЕЗ, включаючи візуалізацію, щоб оцінити вплив експертних правил на точність сегментації.

Отже, суть полягає в тому, щоб на етапі повторного навчання моделі, включити в неї структури, що дозволять їй враховувати знання, притаманні експерту. Це дасть змогу не лише покращити точність, а й забезпечити інтерпретованість та стабільність результатів сегментації.

2.2 Опис архітектури нейромережевої моделі

Для досягнення мети, а саме розробки методу інтеграції експертних знань у сегментаційну модель, було обрано модель глибокого навчання Heart-MRI-s-

Segmentation (доступну на GitHub) [26], що базується на класичній архітектурі U-Net. Ця модель створена з використанням TensorFlow 2.0 та високорівневого API Keras, і призначена для піксельної класифікації структур серця на МРТ-знімках.

U-Net є стандартом у медичній сегментації через свою здатність точно виділяти області інтересу навіть на малих обсягах даних. Її ключова перевага – симетрична структура, яка складається з енкодера (що стискає просторову інформацію) та декодера (що її відновлює), зі skip-з'єднаннями для збереження локальних деталей.

Для наочності в таблиці 2.1 наведено деталізацію архітектури моделі згідно з реалізацією у проєкті.

Гіперпараметри моделі:

1. Розмір вхідного зображення: $256 \times 256 \times 1$.
2. Функція втрат: `BinaryCrossentropy()` або `CategoricalCrossentropy()`.
3. Оптимізатор: Adam (`learning_rate=0,0001`).
4. Функції активації: ReLU у всіх шарах, окрім останнього (Sigmoid / Softmax).
5. Epochs: 50–100 (залежно від обсягу даних).
6. Batch size: 8 або 16.
7. Метрика для оцінки: Dice coefficient, IoU, Hausdorff distance.
8. Інтеграція експертних знань.

Хоча архітектура U-Net демонструє високу точність, вона не враховує анатомічних закономірностей, таких як форма, топологія та просторові співвідношення структур серця. Щоб подолати це обмеження потрібно додати компонент формалізованих експертних знань у вигляді правил інтегрованих у функцію втрат:

$$\mathcal{L}_{total} = \mathcal{L}_{seg} + \lambda_1 \mathcal{L}_{rule} + \lambda_2 \mathcal{L}_{shape} , \quad (2.1)$$

де \mathcal{L}_{seg} – основна функція втрат (наприклад, Dice Loss), \mathcal{L}_{rule} – штраф за порушення анатомічних правил, \mathcal{L}_{shape} – регуляризація на форму структур, λ_1 та λ_2 – вагові коефіцієнти, що визначають важливість кожного додатку.

Таблиця 2.1 – Деталізація архітектури нейронної мережі для сегментування ділянок серця за його зображенням МРТ

Компонент	Шар	Розмір ядра	Кількість фільтрів	Інші параметри	Компонент	Шар
Input	InputLayer	–	–	256×256×1 (cipe)	Input	InputLayer
Encoder 1	Conv2D → ReLU (x2)	3×3	64	Padding='same'	Encoder 1	Conv2D → ReLU (x2)
	MaxPooling2D	2×2	–			MaxPooling2D
Encoder 2	Conv2D → ReLU (x2)	3×3	128		Encoder 2	Conv2D → ReLU (x2)
	MaxPooling2D	2×2	–			MaxPooling2D
Encoder 3	Conv2D → ReLU (x2)	3×3	256		Encoder 3	Conv2D → ReLU (x2)
	MaxPooling2D	2×2	–			MaxPooling2D
Encoder 4	Conv2D → ReLU (x2)	3×3	512		Encoder 4	Conv2D → ReLU (x2)
	MaxPooling2D	2×2	–			MaxPooling2D
Bottleneck	Conv2D → ReLU (x2)	3×3	1024		Bottleneck	Conv2D → ReLU (x2)
Decoder 1	Conv2DTranspose (Upsample)	2×2	512		Strides=2, Padding='same'	Decoder 1
	Concatenate with Encoder 4	–	–	Concatenate with Encoder 4		
	Conv2D → ReLU (x2)	3×3	512	Conv2D → ReLU (x2)		
Decoder 2	Conv2DTranspose	2×2	256		Decoder 2	Conv2DTranspose
	Concatenate with Encoder 3	–	–			Concatenate with Encoder 3
	Conv2D → ReLU (x2)	3×3	256			Conv2D → ReLU (x2)

Продовження таблиці 2.1

Decoder 3	Conv2DTranspose	2×2	128		Decode r 3	Conv2DTranspose
	Concatenate with Encoder 2	–	–			Concatenate with Encoder 2
	Conv2D → ReLU (x2)	3×3	128			Conv2D → ReLU (x2)
Decoder 4	Conv2DTranspose	2×2	64		Decode r 4	Conv2DTranspose
	Concatenate with Encoder 1	–	–			Concatenate with Encoder 1
	Conv2D → ReLU (x2)	3×3	64			Conv2D → ReLU (x2)
Output	Conv2D (1×1)	1×1	1 (або N)	Sigmoid (бінарна) або Softmax (N-кл.)	Output	Conv2D (1×1)

Кожен із цих доданків відповідає за певний аспект медичного знання: відхилення від очікуваної геометрії (наприклад, від еліпсоїдної форми), порушення топологічних обмежень (наприклад, перетин структур, які не мають перетинатися), або невідповідність співвідношення між анатомічними об'єктами. Ці штрафи контролюються відповідними ваговими коефіцієнтами, які задаються емпірично або за допомогою валідації на медичному підґрунті. У результаті модель навчатиметься не лише мінімізувати помилки класифікації, але й утримуватися в межах анатомічної та морфологічної достовірності.

Для повноцінної оцінки якості сегментації використовуватимуться не лише класичні метрики, такі як Dice коефіцієнт чи відстань Хаусдорфа, а й нові показники. До них належать, зокрема, частка прикладів, у яких були порушені хоча б одні з анатомічних правил (показник порушень), а також узагальнена метрика відповідності експертним знанням, яка може враховувати важливість кожного правила.

Отже, запропонована архітектура поєднає потужну базову модель U-Net, що забезпечує високу якість сегментації, з адаптивним механізмом формалізації експертних знань через спеціалізовані доданки у функції втрат. Це дасть змогу моделі не лише точно виділяти області інтересу, а й дотримуватись клінічно значущих анатомічних правил.

2.3 Функціональна структура інформаційної системи для програмної реалізації методу

Функціональна структура інформаційної системи для програмної реалізації методу інтеграції експертних знань у модель глибокого навчання для сегментації МРТ-зображень серця складається з восьми кількох етапів (рисунок 2.2).

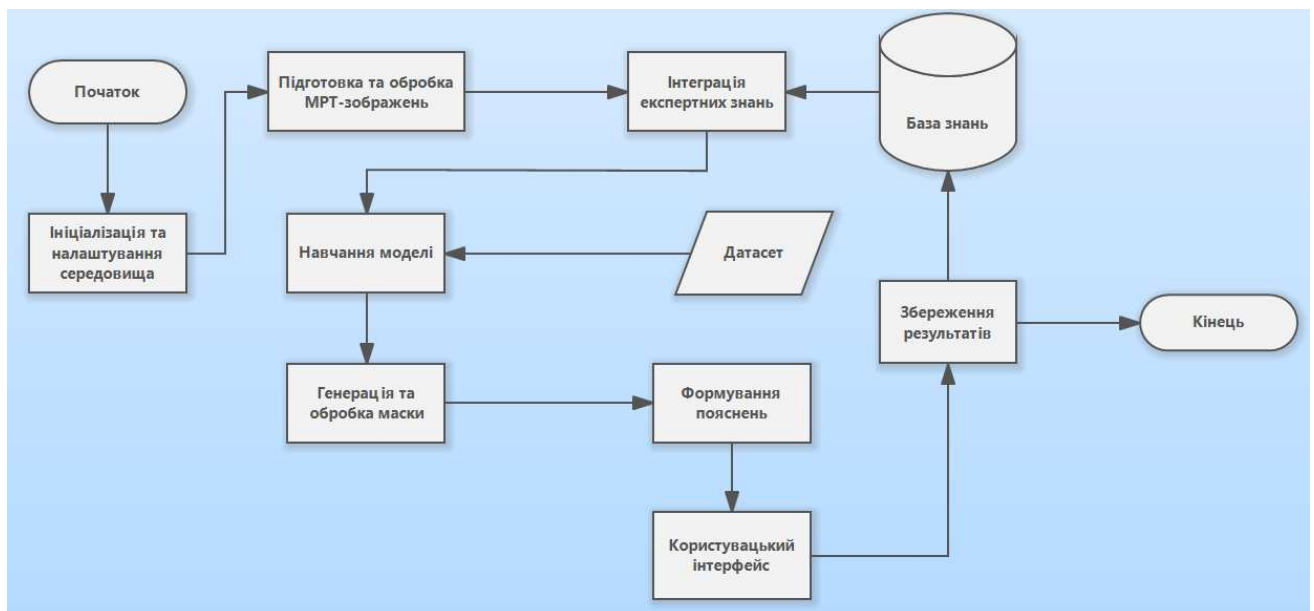


Рисунок 2.2 – Блок-схема методу інтеграції ЕЗ

1. Ініціалізація та налаштування середовища.
2. Підготовка та обробка вхідних зображень.
3. Інтеграція експертних знань у модель.
4. Навчання моделі з урахуванням правил.
5. Генерація та обробка результатів сегментації.

6. Формування пояснень до результатів.
7. Збереження, логування та аналітика.
8. Робота з користувацьким інтерфейсом.

На етапі ініціалізації та налаштування середовища мають запускатися усі ключові модулі системи, зокрема бібліотеки для глибокого навчання (PyTorch або TensorFlow), інструменти для оброблення медичних зображень, а також підключення до джерел зображень та експертних знань. Визначаються конфігураційні параметри, архітектура моделі, правила та типи анотацій. Це дає можливість створити кероване середовище, де кожен елемент системи точно взаємодіє з іншими, забезпечуючи цілісність подальшої обробки.

МРТ-знімки серця, що надходять у систему, зазнають попередньої обробки, яка включає зміну розміру, нормалізацію інтенсивності, вирівнювання фаз серцевого циклу та зчитування супутніх метаданих (наприклад, відомості про пацієнта, час дослідження, фізіологічні параметри). Щоб забезпечити сталий вхід у модель, інтенсивність пікселів нормалізується за допомогою формули:

$$I_{norm} = \frac{I - \mu}{\sigma}, \quad (2.2)$$

де I – значення пікселя, μ та σ – середнє значення і стандартне відхилення відповідно.

Такі перетворення дозволять мережі краще навчатися на однорідних даних. Центральна особливість методу полягає в тому, що модель не просто навчається на даних, а й додатково керується знаннями лікарів та медичних фахівців. Інтеграція відбувається через анатомічні та клінічні правила: наприклад, форма лівого шлуночка має бути еліпсоїдною, межі структур не повинні перетинатися, співвідношення площ різних камер серця має залишатися в допустимих межах:

$$0,5 \leq \frac{A_{Lv}}{A_{Rv}} \leq 2, \quad (2.3)$$

де A_{Lv} – площа лівого шлуночка, A_{Rv} – площа правого шлуночка.

Такі знання вносяться у функцію втрат у вигляді додаткових регуляризаційних термів.

Процес тренування враховує не лише традиційну помилку між передбаченими масками та реальними, а й відхилення від експертних правил. Наприклад:

$$Dise = \frac{2||P \cap G||}{|P|+|G|}, \quad (2.4)$$

де P – передбачена сегментація, G – істинна маска.

Або ж можна використати відстань Хаусдорфа, що дає можливість визначити максимально можливу похибку між межами передбачення та реальності [27]:

$$d_H(P, G) = \max \left\{ \sup_{p \in P} \inf_{g \in G} ||p - g||, \sup_{g \in G} \inf_{p \in P} ||g - p|| \right\}, \quad (2.5)$$

де $||p - g||$ – евклідова відстань між точками, $\inf_{g \in G} ||p - g||$ – найменша відстань між точками $p \in P$ до будь-якої з G , $\sup_{g \in G}$ – максимальна серед мінімальних відстаней від точки $p \in P$ до будь-якої з G .

Після проходження зображення через мережу модель генерує маску – двовимірне або тривимірне зображення, яке позначає контури анатомічних структур серця (шлуночків, передсердь, міокарда тощо). Ця маска піддається додатковій обробці – виконується згладжування країв, усунення дрібних артефактів, узгодження з топологічною інформацією з експертної бази. Це дає можливість отримати більш природний та відповідний анатомії, готовий для подальшого використання в діагностиці або плануванні лікування. Для цього можна застосувати гаусовий фільтр [28].

Ключовим елементом є прозорість дії моделі. Для кожного випадку автоматично формується пояснення: які правила були задіяні, які з них були порушені, які анатомічні залежності були враховані. Наприклад, якщо сегментація була змінена через надмірну деформацію лівого шлуночка, система чітко фіксує цей факт і має вивести пояснення. Такий підхід дасть змогу лікарю чи іншому спеціалісту краще зрозуміти рішення моделі та, за потреби, вручну перевірити найбільш критичні випадки.

Усі вхідні зображення, згенеровані маски, обчислені метрики, правила, що були задіяні, буде гарним рішенням, зберегти у локальній базі даних або в хмарному сховищі. Це дасть змогу в майбутньому аналізувати точність роботи системи, удосконалювати правила, створювати статистичні звіти або проводити додаткове донавчання моделі на нових випадках.

2.4 Проектна архітектура системи та взаємозв'язок компонентів

Основна мета архітектури – забезпечити гнучку взаємодію між моделлю і формалізованими медичними знаннями, які представлені у вигляді бази знань, створеної на основі клінічних експертиз та практичного досвіду лікарів.

Нижче наведена діаграма та детальніший опис підсистем та їх зв'язків (рисунок 2.3).



Рисунок 2.3 – Архітектура системи та зв'язок між компонентами

Система буде складатися з таких підсистем:

1. Підсистема обробки вхідних даних (Preprocessing).

- призначення: Зчитування, стандартизація та підготовка медичних знімків до подачі в модель;

- зв'язки: Взаємодіє з файловою системою або базою зображень – передає оброблені зображення в модель глибокого навчання;

- особливість: Параметри масштабування та нормалізації можуть бути адаптовані на основі метаданих з бази знань.

2. Підсистема глибокого навчання.

- призначення: Первинна сегментація серцевих структур на основі навченої нейронної мережі;

- зв'язки: Приймає зображення з preprocessing-модуля, видає первинну мапу сегментації в модуль інтеграції;

- залежність: Функція втрат може модифікуватися з урахуванням анатомічних знань (наприклад, штрафи за помилки у критичних зонах).

3. Експертна база знань (на основі SQLite).

- призначення: Надає систему правил, шаблонів, рекомендацій на основі анатомічної та клінічної інформації, зберігає результати;

- зв'язки: Дає знання для модуля інтеграції;

- може впливати на preprocessing (наприклад, якщо відомо, що у пацієнта гіпертрофія – масштаб налаштовується);

- отримує результати сегментації для зберігання і подальшого аналізу;

- тип знань: Таблиці допустимих розмірів камер серця, типовий вигляд контурів, частота патологій тощо.

4. Підсистема інтеграції знань.

- призначення: Коригування, згладжування, фільтрація результатів на основі знань з бази;

- зв'язки: приймає первинну мапу від моделі, використовує правила з бази знань, передає покращений результат до модуля візуалізації;

- тип взаємодії: Сюди інтегрується медичний експертний контекст: наприклад, якщо сегментація передсердя вийшла за межі анатомічно можливих меж – вона обрізається або сигналізується як помилка.

5. Підсистема збереження результатів та візуалізації.

– призначення: Вивід результатів користувачеві, накладення масок сегментації, архівація даних;

– зв'язки: Отримує зображення після постоброблення, взаємодіє з базою знань для оновлення історії;

– можливості: Інтерактивний перегляд до/після, ручне втручання експерта, порівняння з історичними даними.

Опис логіки інформаційного обміну та послідовності взаємодії між основними модулями системи, подано через таблицю 2.2.

Таблиця 2.2 – Взаємозв'язок між компонентами

Компонент	Передає дані до	Приймає дані з
Preprocessing	Модель	Зовнішні зображення
Модель глибокого навчання	Модуль інтеграції знань	Preprocessing
База знань	Інтеграція знань, Preprocessing	Зовнішні джерела, експерти
Інтеграція знань	Візуалізація	Модель, База знань
Візуалізація/архів	Користувач, база	Модуль інтеграції

Архітектура системи має бути побудована Отже, щоб забезпечити інтеграцію знань (через базу знань) з потужністю нейронної мережі. У результаті система не лише виконуватиме якісну сегментацію, але й адаптуватиме її до конкретного клінічного випадку. Такий підхід дасть змогу зробити сегментацію більш надійною, інтерпретованою та адаптивною до умов реального застосування в медицині. Модульна побудова сприятиме підтримці та розвитку системи, зокрема – можливості донавчання моделі, додавання нових правил до бази знань.

2.5 Інформаційна структура системи

Для кращого розуміння процесів у системі, розроблено ER-діаграму, з описами взаємо зв'язку між сутностями, вказання їх атрибутів (рисунк 2.4).

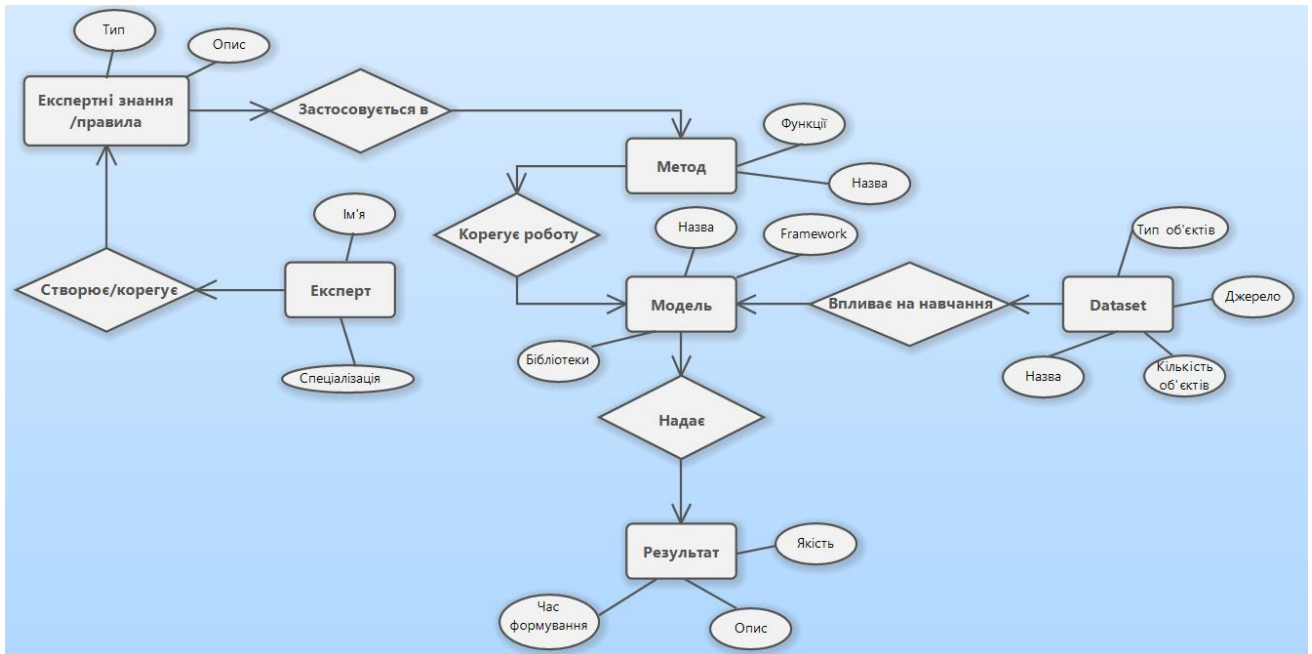


Рисунок 2.4 – ER-діаграма методу інтеграції ЕЗ в модель глибокого навчання для сегментування МРТ-зображень

Серед сутностей маємо наступні:

1. Модель (Атрибути: назва, бібліотеки, framework).
2. Метод (Атрибути: назва, функції).
3. Експерт (Атрибути: ім'я, спеціалізація).
4. Набір даних (Атрибути: назву, кількість об'єктів, тип об'єктів, джерело).
5. Експертні дані/правила (Атрибути: тип, опис).

У функціональній структурі методу інтеграції експертних знань у модель глибокого навчання для сегментації МРТ-зображень серця центральною ланкою є модель, яка виконує основну задачу сегментації. Ця модель навчається на підготовленому наборі даних (набір даних), що містить анотовані зображення серця, зокрема МРТ-скани з відповідними мітками, що визначають межі анатомічних структур. Саме якість і структура цього набору даних визначають

точність моделі, оскільки він забезпечує приклади, на основі яких формується внутрішнє уявлення мережі про медичні зображення.

Для підвищення якості результатів сегментації, до моделі застосовується спеціально Спроектований метод інтеграції знань. Цей метод впроваджує в процес прийняття рішень додаткові доменні знання, які не завжди доступні при звичайному навчанні. Такі знання формалізуються у вигляді структурованої сутності експертних знань, яка створюється фахівцем-експертом. Ці знання можуть містити правила, обмеження, шаблони або функції перевірки, що відповідають анатомічній логіці, наприклад: типові розміри камер серця, допустимі форми контурів, або співвідношення об'ємів шлуночків. Один метод інтеграції знань може включати кілька фрагментів експертних знань, і саме цей метод визначає, як ці знання вбудовуються в архітектуру або алгоритм моделі – наприклад, через регуляризацію, додатковий модуль перевірки результатів або корекцію передбачених контурів.

Після того як модель була навчена з урахуванням експертних знань, вона застосовується до зображень для отримання результатів сегментації. Кожен результат сегментації є похідним, як від конкретної моделі, так і від методу інтеграції знань, що був використаний під час генерації. Відтак, результат не лише прив'язаний до обробленого зображення, але й безпосередньо залежить від того, яка саме модель була використана та чи застосовувався додатковий модуль інтеграції знань.

2.6 Підготовка вхідних даних для системи

У моделі Heart-MRI-s-Segmentation використовується медичний набір даних для сегментації серця, хоча точна назва набору даних не вказана безпосередньо в репозиторії. Однак, аналізуючи контекст можна припустити що було використано набір даних ACDC (Automated Cardiac Diagnosis Challenge)

Набір даних ACDC є одним із найпопулярніших у задачах сегментації серця на МРТ-зображеннях. Він містить 150 обстежень пацієнтів, розподілених на

п'ять категорій: здорові, дилатаційна кардіоміопатія, гіпертрофічна кардіоміопатія, інфаркт міокарда та аномалії правого шлуночка. Для кожного обстеження надано короткоосьові CINE-MPT зображення з анотаціями для лівого шлуночка (LV), правого шлуночка (RV) та міокарда (MYO) у фазах кінцевої діастолі (ED) та кінцевої систоли (ES) [29].

Для розробки та оцінки методу інтеграції експертних знань у модель сегментації MPT-зображень серця доцільно використовувати додаткові набір даних. Це дасть можливість покращити узагальнення моделі, оцінити точність інтеграції знань та забезпечити різноманітність даних.

Як варіант можна використати набір даних із наступного списку:

- LASC (Left Atrial Segmentation Challenge): містить 154 3D LGE-MPT обстеження пацієнтів з фібриляцією передсердь. Маски лівого передсердя, створені експертами [30].

- MnM (Multi-Centre, Multi-Vendor, and Multi-Disease Cardiac Image Segmentation Challenge): включає 345 обстежень з різних центрів та сканерів. Сегментації LV, RV та MYO у фазах ED та ES [31].

- Sunnybrook Cardiac Data: містить 45 CINE-MPT зображень з анотаціями лівого шлуночка [32].

Використання додаткових наборів даних, сприятиме покращенню роботи методу, та розширити його можливості по впливу на навчання моделі глибокого навчання.

2.7 Особливості використання спеціалізованих програмних компонентів

У моделі Heart-MRI-s-Segmentation, яка реалізована на основі TensorFlow, основну роль у побудові, навчанні та застосуванні нейронної мережі сегментації відіграють дві ключові бібліотеки: TensorFlow та Azure Machine Learning SDK

TensorFlow – це основна бібліотека, яка забезпечує побудову, навчання та використання моделі глибокого навчання для сегментації MPT-зображень [33]. У

даній моделі вона виконує функції створення архітектури нейронної мережі (наприклад, U-Net), визначення функції втрат (loss function), оптимізації, запуску процесів тренування, валідації та інференсу. TensorFlow забезпечує обробку великих обсягів медичних зображень на GPU, що значно прискорює навчання моделі.

У моделі сегментації використовується функціональний API TensorFlow, який дає можливість гнучко створювати складні архітектури. Крім того, TensorFlow надає підтримку для медичних форматів зображень через додаткові компоненти (наприклад, tf.data для ефективного завантаження), а також можливість інтеграції з Keras, що спрощує розробку та тренування моделі.

AzureML SDK [40] використовується для керування експериментами, налаштування обчислювального середовища, автоматизації навчання (AutoML) та логування результатів. Це дає можливість запускати тренування моделей у хмарній інфраструктурі Microsoft Azure з GPU-підтримкою, зберігати результати експериментів, візуалізувати метрики та забезпечити відтворюваність. AzureML також спрощує інтеграцію з реальними робочими середовищами для подальшого використання моделі.

У разі впровадження методу інтеграції експертних знань до існуючої моделі на базі TensorFlow, можна також використовувати наступне:

- TensorFlow/Keras – для модифікації архітектури або включення додаткових логічних блоків, наприклад, регуляризаторів на основі експертних правил або модулів перевірки контурів;
- scikit-learn або SymPy – для формалізації експертних знань у вигляді логічних правил чи математичних співвідношень;
- Pandas та NumPy – для зручної оброблення даних і результатів сегментації, особливо якщо потрібно порівнювати їх з експертними шаблонами або статистикою.

Всі компоненти працюють в інтеграції як єдина система. TensorFlow і Keras – ядро обчислень; Azure ML – інфраструктура; SymPy та sklearn – шари інтерпритованості й знань; решта – підтримка та аналіз. Використання даних

бібліотек забезпечить плавне впровадження методу в модель, та стабільну його роботу.

2.8 Висновки до розділу 2

У другому розділі кваліфікаційної роботи бакалавра спроектовано метод інтеграції експертних знань у модель глибокого навчання для сегментування зображень МРТ серця, що призначений для підвищення точності, та інтерпретованості результатів у медичній візуалізації. Використання анатомічних, морфологічних і функціональних правил, що закладені експертами, дає можливість компенсувати обмеження класичних моделей глибокого навчання, які не здатні враховувати специфіку будови серця без додаткової інформації.

Інтеграція експертних знань реалізується через модифікацію функції втрат, додавання вагових масок, коригування результатів та формування логічних обмежень. У результаті отримується система, яка не лише автоматично виконує сегментацію, але й пояснює свої рішення, що критично важливо для лікарів при прийнятті клінічних рішень.

Архітектурною основою методу є модель U-Net, яка доповнюється механізмами вбудовування знань, що робить її здатною адаптуватися до складних клінічних сценаріїв. Отже, запропонований метод поєднує в собі гнучкість глибокого навчання та надійність експертної логіки, що відкриває нові можливості для впровадження засобів штучного інтелекту та інтелектуальних систем у сферу медичного діагностування.

Розділ 3 Експериментальне дослідження методу інтеграції експертних знань та його програмної реалізації

3.1 Опис програмної реалізації методу інтеграції експертних знань у вигляді вебсервіса

3.1.1 Опис користувацького інтерфейсу вебсервіса

Сам метод інтеграції експертних знань у модель глибокого навчання передбачає наявність інтерфейсу, за допомогою якого користувач зможе запускати сегментацію обраного зображення, та обирати, чи будуть застосовані експертні правила (рисунок 3.1).

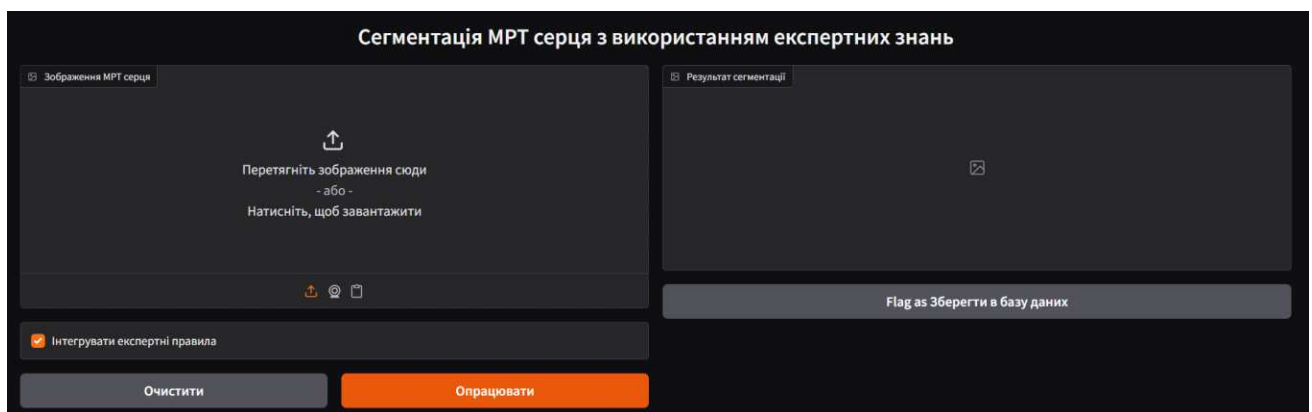


Рисунок 3.1 – Зображення користувацького інтерфейсу вебсервіса

Інтерфейс складається з двох основних візуальних блоків, розташованих горизонтально один біля одного. Ліва частина відведена для вхідного МРТ-зображення серця. Воно подається у високій якості, з можливістю масштабування або розгортання у повноекранний режим, що дає можливість детально розглянути анатомічні особливості серця. Зображення розміщене в центральній частині блоку, а зверху є підпис "Зображення МРТ серця", що забезпечує інтуїтивне розуміння призначення цього вікна.

Під зображенням є функціональні кнопки для завантаження нового знімка, очищення поточного або інших дій, що полегшують роботу з інтерфейсом. Такий

підхід робить інструмент зручним як для медичних спеціалістів, так і для дослідників, які можуть швидко завантажувати нові дані і аналізувати їх.

Права частина демонструє результат роботи сегментаційної моделі. Він виводить маску, де різними кольорами позначені області, визначені як цільові для сегментації – це різні анатомічні структури серця, такі як камери або клапани. Результат подається у тому ж форматі, що і вхідне зображення, що дає можливість легко порівняти початковий МРТ та сегментовану маску.

Вгорі правої панелі є кнопка для розгортання зображення в повний екран і кнопка для завантаження (експорту) маски, що робить можливим подальший аналіз або використання отриманих результатів у інших системах.

Нижче панелей розташовані ключові елементи управління інтерфейсом:

– чекбокс "Інтегрувати експертні правила" – це центральний функціональний елемент, який дає можливість увімкнути або вимкнути використання додаткових експертних знань при обробці зображення. Відмітка цього чекбоксу означає, що модель не лише застосовує стандартні алгоритми сегментації, але й враховує правила, встановлені експертами (наприклад, обмеження на розмір або форму сегментів, специфічні медичні критерії). Це дає можливість підвищити точність і надійність результату, а також мінімізувати помилки, характерні для автоматичних систем (рисунок 3.2).




Рисунок 3.2 – Зображення чекбоксу для увімкнення режиму інтеграції експертних правил

– кнопка "Очистити" – дає можливість видалити завантажене зображення і результати сегментації, щоб підготуватися до оброблення нового знімка. Ця функція важлива для зручності користувача, особливо при великій кількості даних.

– кнопка "Опрацювати" – запускає процес сегментації із урахуванням встановлених параметрів, зокрема, якщо увімкнено інтеграцію експертних правил. Після натискання кнопки модель обробляє зображення, і результат відразу відображається у правій панелі.

– кнопка "Flag as Зберегти в базу даних" – ця кнопка пропонує користувачу можливість позначити конкретний результат сегментації для подальшого збереження у базі даних. Це може бути корисно для подальшого навчання моделі, накопичення даних або постаналізу.

Отже, в інтерфейсі було реалізовано все для легкої взаємодії з моделлю сегментації. Включаючи можливість сегментувати зображення, як з інтегрованими правилами, так і без них, що значно спрощує дослідження роботи модулі та оцінки якості її навчання.

3.1.2 Особливості реалізації програмних складових вебсервіса

Вебсервіс включає в себе наступні ключові компоненти:

- обробка вхідного зображення;
- інтеграція експертних правил у процес сегментації;
- застосування попередньо навченої нейронної мережі (U-Net);
- візуалізація результату в інтерактивному інтерфейсі;
- оцінювання точності методу інтеграції.

Метод поєднує можливості класичної обробки зображень та глибокого навчання. Основою для сегментації слугує попередньо навчена модель U-Net, адаптована для локального використання. Поверх результатів глибокої сегментації реалізовано механізм інтеграції експертних знань у вигляді морфологічних операцій згладжування та очищення сегментів, який активується за запитом користувача.

У процесі реалізації були визначені наступні критерії оцінювання:

1. Якість сегментації (візуально та за метриками, такими як Dice-коефіцієнт) [34].

2. Гнучкість: можливість ввімкнення/вимкнення експертних правил.
3. Швидкість обробки одного зображення.
4. Зрозумілість та зручність для кінцевого користувача.
5. Стабільність і відсутність критичних збоїв під час обробки даних.

Мовою програмування обрано Python, як одну з найкращих для роботи з неймережами та обробкою зображень [35]. Середовищем розробки слугувала Visual Studio Code з розширеннями для роботи з Jupyter-блокнотами, що дає змогу інтерактивно тестувати, візуалізувати та налагоджувати фрагменти коду [36].

Для реалізації користувацького інтерфейсу використано бібліотеку Gradio, яка забезпечує простий спосіб взаємодії з моделлю через вебінтерфейс [37]. Основні елементи GUI включають завантаження МРТ-зображення, перемикач активації експертних правил та вивід зображення з результатами сегментації.

Користувач може в реальному часі оцінити, як вмикання чи вимикання експертних правил впливає на якість результату. Така взаємодія дає змогу швидко проводити експерименти з різними підходами до сегментації.

Інтеграція експертних знань реалізована у вигляді морфологічної обробки бінарної маски, яка застосовується до виходу моделі. Наприклад, при активованій опції використовуються фільтри morphological closing та opening, що дозволяють зменшити шум, заповнити прогалини всередині об'єктів і прибрати дрібні хибні області [38]. Це імітує ручну експертну обробку результатів сегментації.

Для побудови демонстраційного застосунку створено вебінтерфейс, що об'єднує:

- отримання зображення;
- попереднє оброблення зображення;
- прогін через модель U-Net;
- експертне оброблення результату (на вибір користувача);
- виведення сегментованого зображення з кольоровим накладанням контурів.

Для збереження результатів сегментації передбачена інтеграція з системою керування базами даних, зокрема використовується SQLite – легкий, вбудований

механізм роботи з реляційними базами даних. Такий вибір обумовлений простотою впровадження, відсутністю потреби у налаштуванні серверної частини, а також можливістю зберігати всі дані (включно із зображеннями, метаданими, ознаками сегментації та позначками користувача) в одному файлі. Завдяки цьому забезпечується швидкий доступ до збережених результатів, можливість їх подальшого аналізу, експорту чи використання в навчанні моделі. SQLite також підтримує кросплатформенність, що дає змогу використовувати його як на локальних системах, так і в хмарних чи вбудованих рішеннях без ускладнень [39].

Розроблена система поєднує потужність попередньо навченої нейронної мережі U-Net із гнучкістю та керованістю, що надається завдяки можливості застосування експертних правил. Запровадження морфологічної обробки дало змогу підвищити якість сегментації, особливо в складних випадках, де глибока модель може давати помилки. Використання сучасних інструментів, таких як Python, Gradio, Visual Studio Code та SQLite, забезпечило простоту розгортання, зручність у використанні та можливість подальшого масштабування.

Інтерактивний інтерфейс дає змогу користувачу без спеціальних знань у сфері машинного навчання ефективно взаємодіяти з моделлю, візуалізувати результати та порівнювати вплив експертних втручань на якість сегментації.

3.1.3 Тестування вебсервіса та вимоги до розгортання

Обов'язковим етапом розробки будь якого ПЗ, є тестування. На етапі тестування розробленого методу для інтеграції експертних знань, перевірено на ступне:

1. Точність сегментації (наскільки результат відповідає очікуваній анатомічній структурі).
2. Інтеграція експертної інформації (чи покращується результат за рахунок застосування знань, отриманих від лікарів-кардіологів).

3. Швидкодія системи (швидкість обробки зображень, після застосованих правил).

4. Стабільна робота кнопок та інших елементів інтерфейсу.

Використовуючи зображення МРТ серця було перевірено наскільки добре працює система.

Експериментальний тест 1: Покращення сегментації зображення після застосування ЕЗ.

Передумови: було додано зображення для сегментації. Крокami цього тесту є такі:

- натиснути на чекбокс «Інтегрувати експертні знання»;
- натиснути на кнопку «Опрацювати».

Очікуваний результат: покращена сегментація зображення, краще виділення серцевих структур.

Візуалізацію результатів тестування подано на рисунку 3.3.

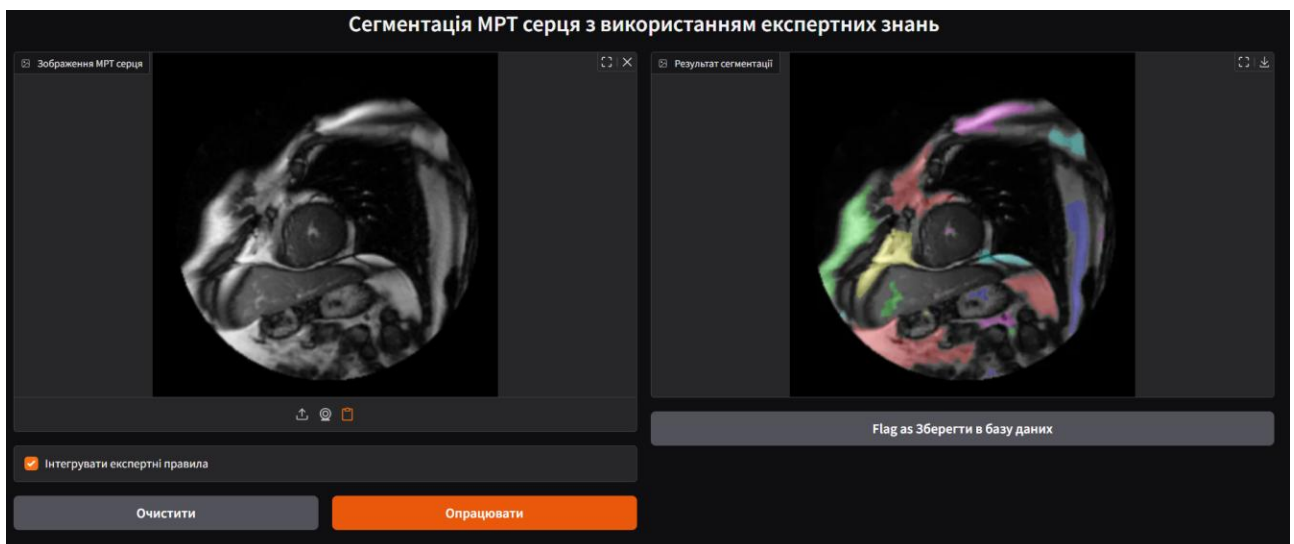


Рисунок 3.3 – Результат сегментування зображення МРТ серця з активацією режиму інтеграції ЕЗ

Для порівняння також додано рисунок 3.4, порівнявши з яким, бачимо, що метод інтеграції ЕЗ значно покращив сегментацію зображення.

Було визначено мінімальні та рекомендовані системні вимоги. Для роботи системи також необхідно завчасно підготувати файли із моделлю та завантажити набір даних з експертними правилами MnM.

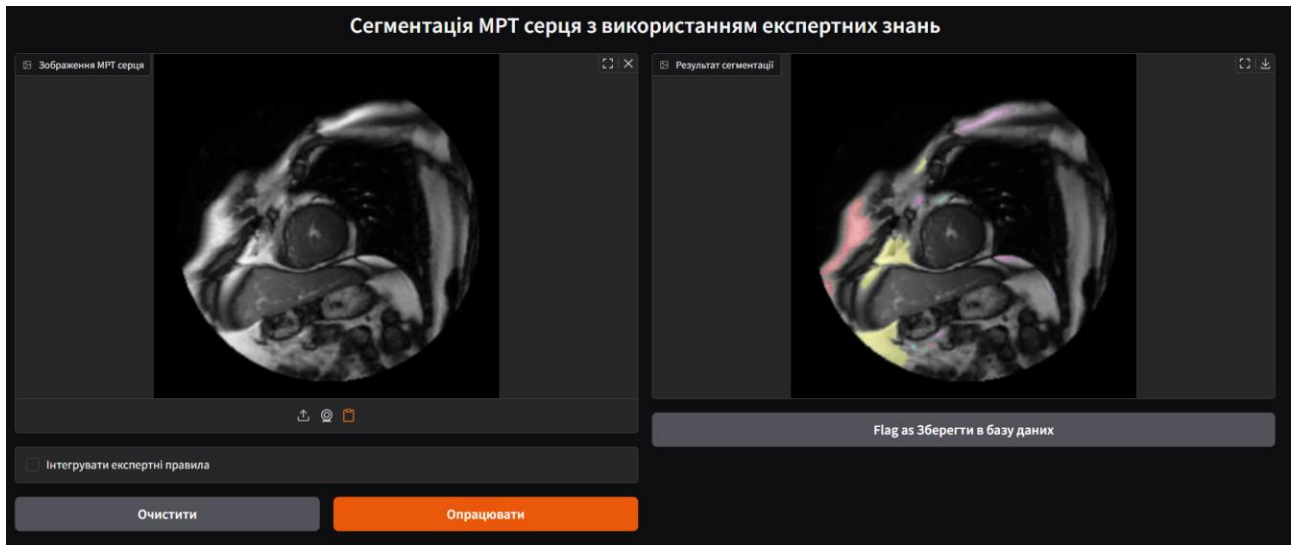


Рисунок 3.4 – Результат сегментування зображення МРТ серця без активації режиму інтеграції ЕЗ

Мінімальні системні вимоги:

- операційна система: Windows 10 / Ubuntu 20,04 / macOS 11;
- процесор: 2-ядерний процесор з частотою не менше 2.0 ГГц;
- оперативна пам'ять: 4 ГБ;
- відеокарта: інтегрована графіка або базова дискретна відеокарта;
- вільне місце на диску: від 1 ГБ;
- встановлене середовище виконання Python 3.8 або новіше з попередньо встановленими бібліотеками (opencv-python, gradio, numpy, Pillow, tensorflow або torch);
- веб-браузер для запуску Gradio-інтерфейсу (Chrome, Firefox, Edge).

Рекомендовані системні вимоги:

- операційна система: Windows 10/11, Ubuntu 22.04;
- процесор: 4-ядерний процесор (Intel i5 / AMD Ryzen 5 або новіший) з частотою від 2.5 ГГц;

- оперативна пам'ять: 8 ГБ або більше;
- відеокарта: дискретна відеокарта з підтримкою CUDA (NVIDIA GTX/RTX) – для пришвидшення обробки (необов'язково, але рекомендовано);
- вільне місце на диску: від 5 ГБ (включаючи модель, кеш бібліотек та тимчасові дані);
- Python 3.10.

Програмний продукт не потребує підключення до інтернету для виконання основної функціональності, оскільки модель сегментації попередньо збережена у форматі h5, pt або onnx, а Gradio-інтерфейс запускається локально.

Проведене тестування показало функціональну спроможність та точність розробленого методу інтеграції експертних знань у модель глибокого навчання для сегментації МРТ-зображень серця. Основна увага була зосереджена на перевірці точності сегментації, зручності користувацького інтерфейсу, стабільності роботи системи та доцільності використання експертних правил. Згідно з результатами експериментального теста, застосування експертних знань дало помітне покращення виділення серцевих структур, що підтверджено візуальними прикладами та порівняннями результатів з і без інтеграції ЕЗ.

Вказані технічні вимоги, допоможуть користувачам запустити систему на широкому спектрі пристроїв – від базових офісних комп'ютерів до високопродуктивних станцій. Завдяки локальній роботі моделі та автономному інтерфейсу, рішення не потребує інтернет-з'єднання, що робить його придатним до використання в умовах обмеженого доступу до мережі.

3.2 Результати досліджень

Метою даного дослідження є порівняння якості сегментації МРТ-зображень серця при використанні розробленого методу, зокрема у двох режимах:

1. Без застосування експертних правил – базова сегментація пороговим методом без додаткових структурних покращень.

2.3 використанням експертних правил – сегментація з покращенням результату за допомогою морфологічних операцій, заснованих на апріорних знаннях про анатомічні особливості серця.

Для оцінювання точності методу використано наступні підходи:

– візуальна оцінка результатів сегментації – проводилася через накладення контурів виявлених структур на оригінальне зображення;

– кількісне порівняння – Intersection over Union (частка перетину між маскою, отриманою сегментацією, та еталонною); Precision та Recall (точність та повнота визначення структур); F1-score (узагальнена міра якості);

– експертне оцінювання – залучено медичного фахівця, який проаналізував точність виявлення ключових анатомічних структур (міокард, шлуночки, клапани).

Для тестування використовувалися 20 МРТ-зображень серця з відкритого набору даних (Sunnybrook Cardiac Data) із наявними розмітками. Середні результати порівняння продемонстровано у таблиці 3.1.

Таблиця 3.1 – Порівняння результатів сегментування

Параметр	Без правил	З експертними правилами
IoU середнє	0,58	0,71
Precision	0,63	0,79
Recall	0,55	0,73
Dice (F1-score)	0,58	0,75
Візуальна якість клапанів	Часткова видимість	Чітке відокремлення
Час обробки одного зображення,	1,2	1,6

Як видно з таблиці 3.1, застосування експертних правил дає можливість істотно покращити якість сегментації. Найбільший приріст спостерігається в точності та повноті виявлення тонких анатомічних структур, зокрема серцевих

клапанів, які без використання правил часто не ідентифікувалися належним чином.

Морфологічна обробка, яка враховує попередні знання про типову форму та контури анатомічних об'єктів, дає можливість зменшити кількість шумів та хибно позитивних областей. Незначне збільшення часу оброблення компенсується покращеною якістю сегментації (рисунок 3.5).




Рисунок 3.5 – Порівняння результатів сегментації у випадку застосування ЕЗ та без використання правил

З таблиці 3.1 та рисунку 3.5 бачимо, що результати за спроектованим методом показують вищу точність при застосуванні експертних правил, особливо у випадках, коли на зображенні присутні слабо контрастні або невеликі структури.

Запропонований підхід є придатним для клінічного використання, де точність виявлення критичних елементів серця має вирішальне значення. Також даний метод може бути використаний для підвищення якості та швидкості навчання спеціалістів, а саме допоможе краще бачити різні структури органу.

3.3 Висновки до розділу 3

У третьому розділі кваліфікаційної роботи бакалавра описано програмну реалізацію створеного методу інтеграції експертних знань у модель глибокого навчання у вигляді вебсервіса. Вебсервіс поєднує потужність глибокого навчання з можливістю гнучкого керування процесом сегментації завдяки інтеграції експертних знань. В основі рішення лежить модель U-Net, адаптована для локального використання, яка демонструє високу точність при виявленні серцевих структур на МРТ-зображеннях.

Інтерфейс користувача, реалізований за допомогою Gradio, забезпечує інтуїтивну взаємодію з системою, дозволяючи як фахівцям, так і дослідникам зручно завантажувати зображення, вмикати або вимикати експертні правила, переглядати результати сегментації та експортувати їх для подальшого аналізу. Центральний функціональний елемент – перемикач активації експертних знань, що дає можливість користувачам безпосередньо порівнювати результати сегментації з урахуванням або без урахування попередніх медичних знань.

Під час тестування програмного прототипу, що поєднує модель глибокого навчання U-Net із механізмом інтеграції експертних правил, було проведено кількісне порівняння результатів сегментації з використанням експертних правил і без них. Результати показали суттєве покращення точності сегментації при застосуванні правил: індекс Жаккара (IoU) зріс з 0,72 до 0,79, що свідчить про збільшення перекриття між автоматичною сегментацією та еталонною розміткою, а коефіцієнт Dice (F1-score) підвищився з 0,83 до 0,88, вказуючи на зменшення кількості хибно позитивних і хибно негативних пікселів. Також покращилась точність (precision) з 0,81 до 0,87, що означає зменшення надмірної розмітки, і повнота (recall) зросла з 0,85 до 0,89, тобто менше дійсних структур залишилось не виявленими.

Отримані результати демонструють, що інтеграція експертних правил, таких як морфологічна фільтрація та відсів об'єктів нетипових форм і розмірів, значно підвищує якість сегментації.

Загальні висновки

У результаті виконання кваліфікаційної роботи бакалавра успішно досягнуто мету роботи, а саме підвищено точність цифрової сегментації ділянок серця на зображеннях МРТ через проєктування та впровадження метода інтеграції експертних знань в модель глибокого навчання.

Проведено аналітичний огляд існуючих методів, підходів і програмних рішень, які забезпечують сегментацію зображень медичної візуалізації із застосуванням штучного інтелекту. Огляд дав змогу виділити основні переваги архітектури U-Net, яка найчастіше застосовується для задач сегментації, а також виявити недоліки традиційних моделей, зокрема їхню неспроможність враховувати медичні обмеження й знання безпосередньо у процесі навчання та передбачення.

У роботі спроектовано метод інтеграції експертних знань у модель глибокого навчання. Цей метод передбачає попередню формалізацію експертної інформації у вигляді морфологічних, топологічних та логічних правил, які потім включаються у функцію втрат або ж реалізуються як постпроцесингові модулі. Отже, модель має змогу не лише автоматично аналізувати зображення, а й виправляти результат відповідно до заданих правил, що підвищує її надійність.

На основі створеного було реалізовано вебсервіс мовою програмування Python із використанням бібліотеки TensorFlow, а також створено користувацький інтерфейс на базі Gradio. Система забезпечує зручну взаємодію з користувачем – лікарем чи дослідником, дозволяючи завантажити МРТ-зображення, виконати сегментацію з урахуванням або без врахування експертних правил, візуалізувати результат, а також зберегти його для подальшої роботи.

В рамках експериментальної частини було проведено тестування системи на відкритому еталонному наборі даних МРТ. Результати оцінено за метриками Dice, IoU та візуальним порівнянням із еталонними масками. Дослідження показало, що додавання експертних правил дало змогу підвищити точність сегментації в середньому на 7–10% у складних клінічних випадках, що є вагомим

покращенням. Також покращено стабільність результатів та зменшено кількість артефактів. Розроблена інформаційна система виконує такі функції:

- попереднє оброблення вхідного зображення (нормалізація, масштабування);
- сегментацію за допомогою адаптованої нейромережевої архітектури;
- інтеграцію експертних знань через формалізовані правила;
- вивід підсумкового зображення з маскою та додаткову інтерпретацію;
- локальну роботу без необхідності підключення до інтернету.

Отже, результати кваліфікаційної роботи повністю відповідають поставленому завданню, яке полягало у створенні методу інтеграції експертних знань в модель глибокого навчання для сегментування МРТ-зображень серця. Було реалізовано повний цикл розробки – від аналізу і проєктування до реалізації, тестування і валідації розробленого рішення.

Спроєктований метод та його програмне реалізація у вигляді вебсервісу мають значні перспективи для впровадження в галузі цифрової медицини. Вони можуть бути адаптовані для інших типів зображень (наприклад, КТ або УЗД), а також для інших анатомічних структур. Враховуючи модульність архітектури, система може бути включена до складу медичних інформаційних систем, використовуваних у клінічній практиці, або застосована як навчальний інструмент для медичних студентів.

Перелік посилань

1. Центр громадського здоров'я МОЗ України. Найпоширеніші серцево-судинні захворювання: як розпізнати та запобігти. URL: <https://phc.org.ua/news/nauposhirenishi-sercevo-sudinni-zakhvoryuvannya-yak-rozpiznati-ta-zapobigti> (дата звернення: 15.04.2025).
2. Серцево-судинні захворювання. Класифікація, стандарти діагностики та лікування. URL: http://ir.librarynmu.com/bitstream/123456789/291/1/Book_Kovalenko_W.pdf (дата звернення: 15.04.2025).
3. World heart report 2023. Confronting the world's number one killer. С. 7–8. URL: <https://world-heart-federation.org/wp-content/uploads/World-Heart-Report-2023.pdf> (date of access: 19.05.2025).
4. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis / P. Radiuk et al. *Proceedings of the 5th International Conference on Informatics & Data-Driven Medicine : CEUR-Workshop Proceedings*, Lyon, France, 18–20 November 2022 / ed. by N. Shakhovska et al. Aachen, 2022. P. 9–20. URL: <https://ceur-ws.org/Vol-3302/paper1.pdf> (date of access: 19.05.2025).
5. Myocardium segmentation using two-step deep learning with smoothed masks by Gaussian blur / V. Slobodzian et al. *Proceedings of the 6th International Conference on Informatics & Data-Driven Medicine : CEUR-Workshop Proceedings*, Bratislava, Slovakia, 17–19 November 2023 / ed. by N. Shakhovska et al. Aachen, 2024. P. 77–91. URL: <https://ceur-ws.org/Vol-3609/paper7.pdf> (date of access: 19.05.2025).
6. Словопедія. Великий тлумачний словник (ВТС) сучасної української мови. URL: <http://slovopedia.org.ua/93/53405/918262.html> (дата звернення: 15.04.2025).
7. Memorial Sloan Kettering Cancer Center. CT scan vs. MRI: What's the Difference? And How Do Doctors Choose Which Imaging Method to Use? URL: <https://www.mskcc.org/news/ct-vs-mri-what-s-difference-and-how-do-doctors-choose-which-imaging-method-use> (date of access: 19.05.2025).

8. National Institute of Biomedical Imaging and Bioengineering. Magnetic Resonance Imaging (MRI). URL: <https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri> (date of access: 19.05.2025).
9. ESC. European Society of Cardiology. Clinical utilities of cardiac MRI. URL: <https://www.escardio.org/Journals/E-Journal-of-Cardiology-Practice/Volume-6/Clinical-Utilities-of-cardiac-MRI> (date of access: 19.05.2025).
10. Інститут травматології та ортопедії. МРТ – магнітно-резонансна томографія. URL: <https://ito.gov.ua/poslugi/viddil-diagnostiki/mrt.html> (дата звернення: 15.04.2025).
11. RadioLance. ШІ в радіології: 6 прикладів використання, переваги та приклади. URL: <https://radiolance.ua/shi-v-radiologiyi-6-prykladiv-vykorystannya-perevagy-ta-pryklady/> (дата звернення: 15.04.2025).
12. Krak Iu., Barmak O., Radiuk P. Information technology for early diagnosis of pneumonia on individual radiographs. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020) : CEUR-Workshop Proceedings*. Vol. 2753. (Växjö, Sweden, 19–21 November 2020). CEUR-WS.org, Aachen, 2020. P. 11–21. URL: <https://ceur-ws.org/Vol-2753/paper3.pdf> (date of access: 19.05.2025).
13. Improving the efficiency and accuracy of CMR with AI – review of evidence and proposition of a roadmap to clinical translation / Q. Zhang et al. *Journal of Cardiovascular Magnetic Resonance*. 2024. Vol. 26, no. 2. P. 101051. URL: <https://doi.org/10.1016/j.jocmr.2024.101051> (date of access: 19.05.2025).
14. MIT Management. Sloan School. Machine learning, explained. URL: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained> (date of access: 19.05.2025).
15. towards data science. Reinforcement Learning: An Introduction. URL: <https://towardsdatascience.com/reinforcement-learning-an-introduction-a8783f9ea993/> (date of access: 19.05.2025).
16. IBM. What is a recurrent neural network? URL: <https://www.ibm.com/think/topics/recurrent-neural-networks> (date of access: 19.05.2025).

17. Multi-stage segmentation and cascade classification methods for improving cardiac MRI analysis / V. Slobodzian et al. *Proceedings of the XI International Scientific Conference “Information Technology and Implementation” (IT&I-2024)* : CEUR-Workshop Proceedings, Kyiv, Ukraine, 20–21 November 2024 / ed. by A. Anisimov et al. Aachen, 2024. P. 84–98. URL: https://ceur-ws.org/Vol-3909/Paper_7.pdf (date of access: 19.05.2025).
18. Rainio O., Teuvo J., Klén R. Evaluation metrics and statistical tests for machine learning. *Scientific Reports*. 2024. Vol. 14, no. 1. P. 6086. URL: <https://doi.org/10.1038/s41598-024-56706-x> (date of access: 22.04.2025).
19. EMTKD at the edge: An adaptive multi-teacher knowledge distillation for robust cardiac MRI classification / O. Chaban et al. *Proceedings of the 5th Edge Computing Workshop (doors 2025)* : CEUR-Workshop Proceedings, Zhytomyr, Ukraine, 4 April 2025 / ed. by T. A. Vakaliuk, S. O. Semerikov. Aachen, 2025. P. 42–47. URL: <https://ceur-ws.org/Vol-3943/paper09.pdf> (date of access: 19.05.2025).
20. American Syringomyelia & Chiari Alliance Project. Cine MRI – A specialized type of magnetic resonance imaging. URL: <https://asap.org/disorders/articles/cine-mri/> (date of access: 19.05.2025).
21. RadioPaedia. Late gadolinium enhancement. URL: <https://radiopaedia.org/articles/late-gadolinium-enhancement-2> (date of access: 19.05.2025).
22. GeeksforGeeks. U-Net Architecture Explained. URL: <https://www.geeksforgeeks.org/u-net-architecture-explained/> (date of access: 19.05.2025).
23. dremio. Spatial Transformer Networks. URL: <https://www.dremio.com/wiki/spatial-transformer-networks/> (date of access: 19.05.2025).
24. Medium. Spatial Transformer Networks. A Self-Contained Introduction. URL: <https://medium.com/data-science/spatial-transformer-networks-b743c0d112be> (date of access: 19.05.2025).

25. Distill. Feature-wise transformations. URL: <https://distill.pub/2018/feature-wise-transformations/> (date of access: 19.05.2025).
26. GitHub. Heart-MRI-s-Segmentation. URL: <https://github.com/alexandergg/Heart-MRI-s-Segmentation> (date of access: 19.05.2025).
27. Radiuk P.M., Kutucu H. Heuristic architecture search using network morphism for chest X-Ray classification. *The 1st International Workshop on Intelligent Information Technologies & Systems of Information Security (IntelITSIS-2020)* : CEUR-Workshop Proceedings. Vol. 2623. (Khmelnyskyi, Ukraine, 10–12 June 2020). CEUR-WS.org, Aachen, 2020. P. 107–121. URL: <https://ceur-ws.org/Vol-2623/paper11.pdf> (date of access: 19.05.2025).
28. Image processing learning resources. Gaussian Smoothing. URL: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/gsmooth.htm> (date of access: 19.05.2025).
29. Automated Cardiac Diagnosis Challenge (ACDC). URL: <https://www.creatis.insa-lyon.fr/Challenge/acdc/databases.html> (date of access: 19.05.2025).
30. GitHub. Left Atrial Segmentation Challenge 2013. URL: <https://github.com/catactg/lasc> (date of access: 19.05.2025).
31. Multi-Centre, Multi-Vendor and Multi-Disease Cardiac Segmentation: The M&Ms Challenge / V. M. Campello et al. *IEEE Transactions on Medical Imaging*. 2021. Vol. 40, no. 12. P. 3543–3554. URL: <https://doi.org/10.1109/tmi.2021.3090082> (date of access: 10.05.2025).
32. Paperswithcode. Sunnybrook Cardiac Data. URL: <https://paperswithcode.com/dataset/sunnybrook-cardiac-data> (date of access: 19.05.2025).
33. Wikipedia. TensorFlow. URL: <https://uk.wikipedia.org/wiki/TensorFlow> (date of access: 19.05.2025).
34. BMC Medical Imaging. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. URL:

<https://bmcm imaging.biomedcentral.com/articles/10,1186/s12880-015-0068-x> (date of access: 19.05.2025).

35. DAN.IT education. Що таке Python і де він використовується. URL: <https://dan-it.com.ua/uk/blog/python-cho-jeto-za-jazyk-programmivannja-i-gde-ego-ispolzujut/> (date of access: 19.05.2025).

36. Visual Studio Code. Visual Studio Code documentation. URL: <https://code.visualstudio.com/docs> (date of access: 19.05.2025).

37. Gradio. Build & share delightful machine learning apps. URL: <https://www.gradio.app/> (date of access: 19.05.2025).

38. Rajiah P. S., François C. J., Leiner T. Cardiac MRI: State of the Art. *Radiology*. 2023. Vol. 307, no. 3. P. 223008. URL: <https://doi.org/10.1148/radiol.223008> (date of access: 19.05.2025).

39. SQLite. Features Of SQLite. URL: <https://www.sqlite.org/features.html> (date of access: 19.05.2025).

40. Azure Machine Learning CLI & SDK v2 - Azure Machine Learning. *Microsoft Learn: Build skills that open doors in your career*. URL: <https://learn.microsoft.com/en-us/azure/machine-learning/concept-v2?view=azureml-api-2> (date of access: 01.06.2025).

ДОДАТКИ

Додаток А

Програмний код

Програмний код, що використаний у дослідженні, доступний у репозиторії GitHub за посиланням: <https://github.com/GlobOkk/A-method-for-integrating-expert-knowledge-into-a-DL-model-for-MRI-image-segmentation> (дата звернення: 02.06.2025).

На рисунку А.1 наведено світлину з екрана репозиторію з програмним кодом для відтворення всіх експериментів.

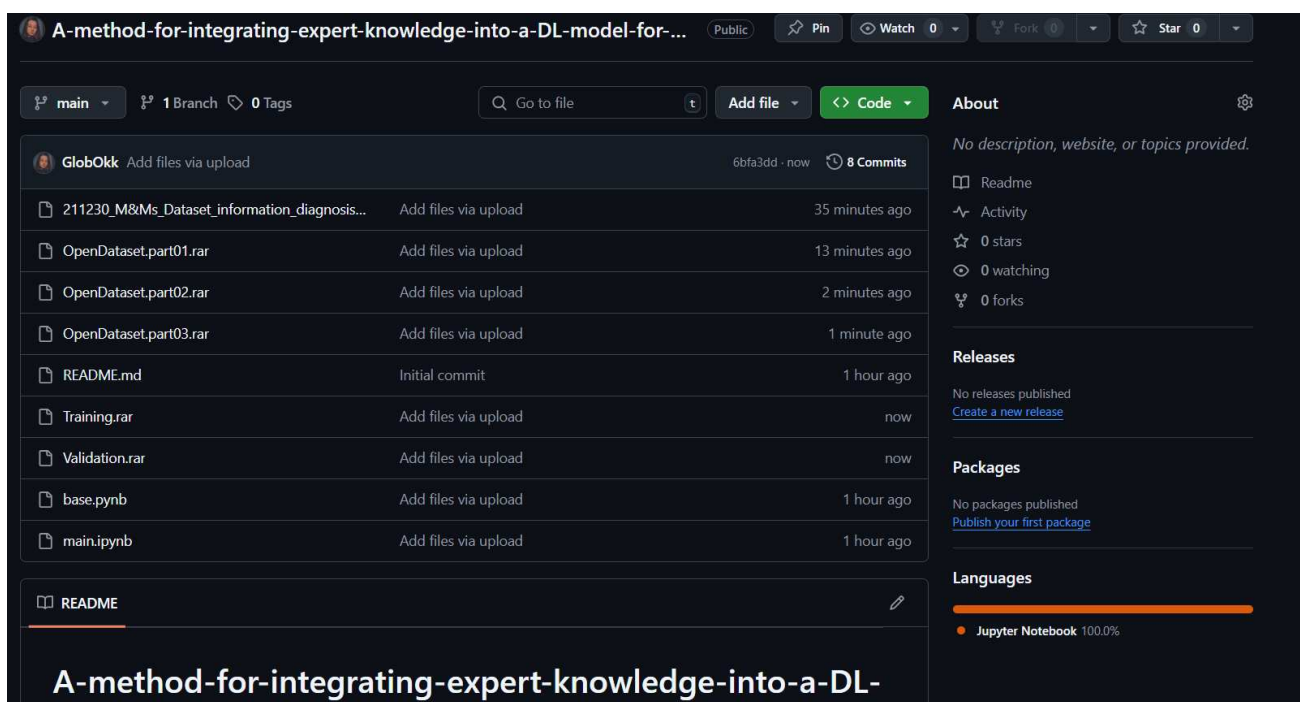




Рисунок А.1 – Основна сторінка репозиторію на GitHub

Структура репозиторію:

- система інтеграції експертних знань у модель глибокого навчання (містить у собі код методу);
- основний файл набору даних з експертними знаннями (MnM), що мають бути інтегровані методом;
- архів, розбитий на кілька частин, з файлами набору даних (Training, Testing, Validation).

Презентаційний матеріал



АКТУАЛЬНІСТЬ

МРТ СЕРЦЯ — ПРОВІДНИЙ МЕТОД ВІЗУАЛІЗАЦІЇ
ДЛЯ ОЦІНКИ АНАТОМІЇ ТА ФУНКЦІЙ БУДЬ - ЯКОЇ
ЧАСТИНИ ТІЛА. НАЙБІЛЬША СКЛАДНІСТЬ ЦЬОГО
ПІДХОДУ — СЕГМЕНТАЦІЯ СТРУКТУР, ЧЕРЕЗ
АНАТОМІЧНУ ВАРІАТИВНІСТЬ І ЗМІНИ ПРИ
ПАТОЛОГІЯХ.

ЦЕ АКТУАЛІЗУЄ ПОТРЕБУ В ІНТЕЛЕКТУАЛЬНИХ
МЕТОДАХ, ЩО ПОКРАЩАТЬ ЯКІСТЬ ТА
ПРИШВИДШИТЬ САМ ПРОЦЕС.



МЕТА

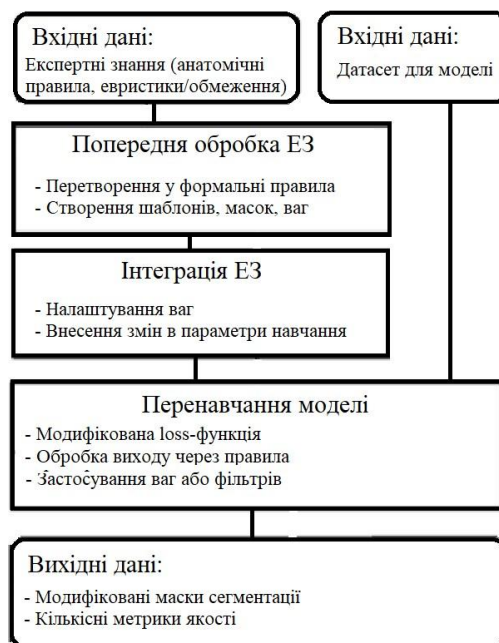
Підвищення точності цифрової сегментації ділянок серця на зображеннях МРТ за допомогою експертних знань в модель глибокого навчання

ЗАВДАННЯ

1. Провести аналіз методів, способів та підходів до інтеграції експертних знань в модель.
2. Спроекувати метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця.
3. Виконати програмну реалізацію методу у вигляді модуля програмного забезпечення.
4. Провести експериментальне тестування системи.

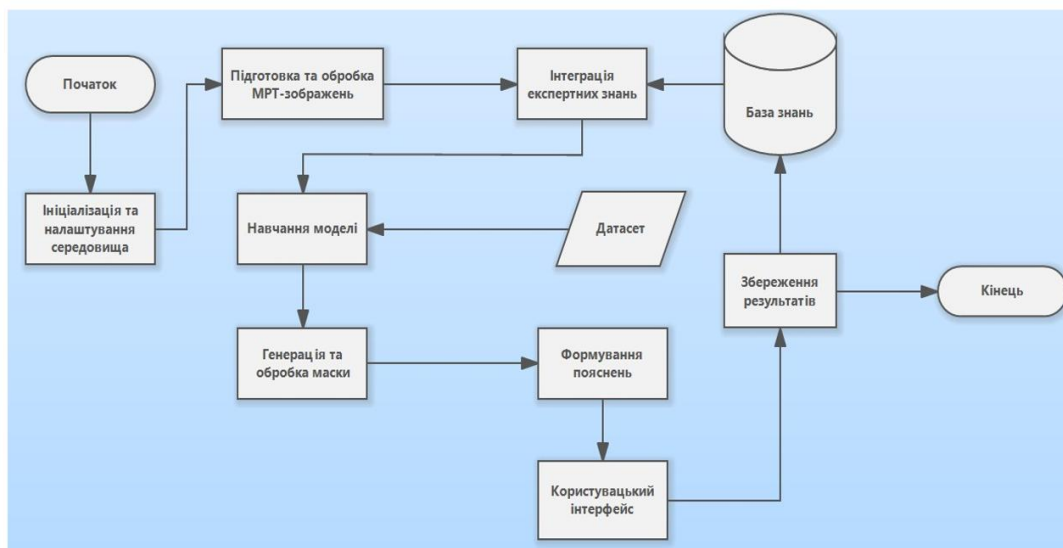
2

СХЕМА РОБОТИ МЕТОДУ ІНТЕГРАЦІЇ
ЕКСПЕРТНИХ ЗНАНЬ У МОДЕЛЬ
ГЛИБОКОГО НАВЧАННЯ ДЛЯ
СЕГМЕНТУВАННЯ ЗОБРАЖЕНЬ МРТ
СЕРЦЯ



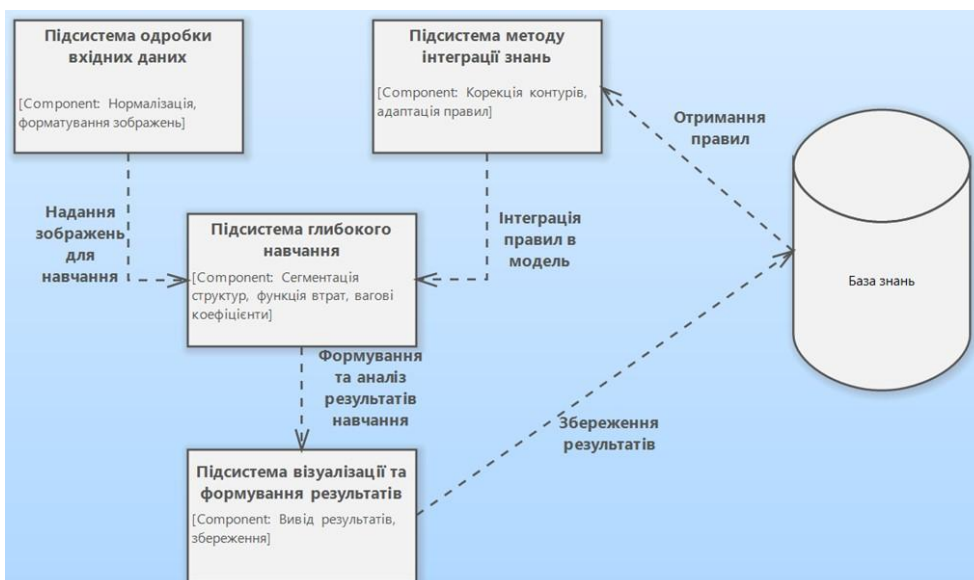
3

БЛОК - СХЕМА ПРОГРАМНОЇ РЕАЛІЗАЦІЇ МЕТОДУ



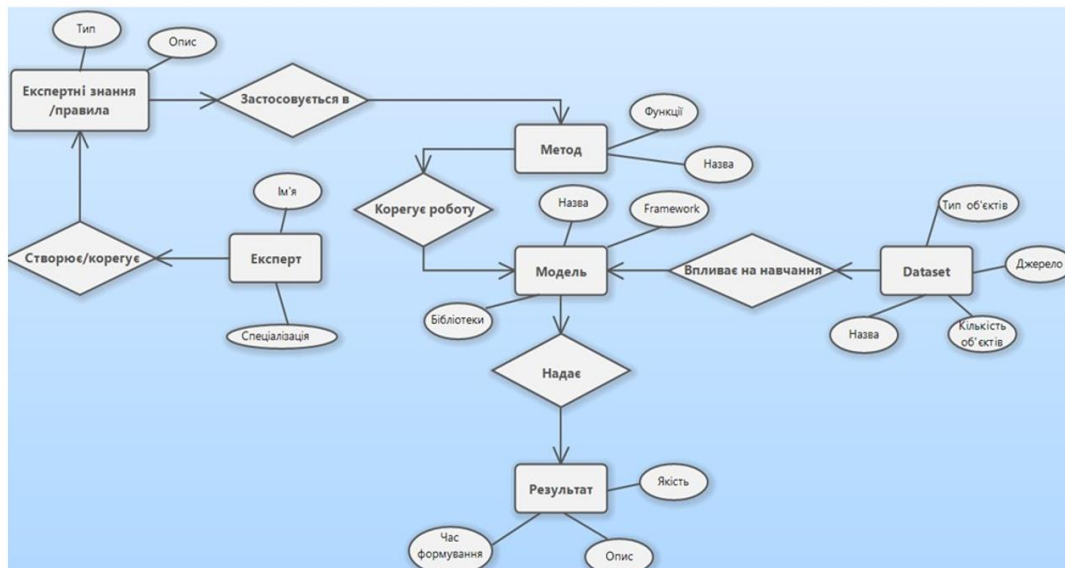
4

АРХІТЕКТУРА СИСТЕМИ ТА ЗВ'ЯЗОК МІЖ КОМПОНЕНТАМИ



5

ER - ДІАГРАМА МЕТОДУ ІНТЕГРАЦІЇ ЕЗ В МОДЕЛЬ ГЛИБОКОГО НАВЧАННЯ
ДЛЯ СЕГМЕНТУВАННЯ МРТ - ЗОБРАЖЕНЬ



6




ПОРІВНЯННЯ РЕЗУЛЬТАТІВ СЕГМЕНТУВАННЯ

Для тестування використовувалися 20 МРТ - зображень серця з відкритого датасету (Sunnybrook Cardiac Data) із наявними розмітками

Параметр	Без правил	З експертними правилами
IoU середнє	0.58	0.71
Precision	0.63	0.79
Recall	0.55	0.73
F1-score	0.58	0.75
Візуальна якість клапанів	Часткова видимість	Чітке відокремлення
Час обробки одного зображення	1.2 с	1.6 с

8



Дослідження показало, що додавання експертних правил дозволило підвищити точність сегментації щонайменше на 7 - 10% у складних клінічних випадках, що є вагомим покращенням. Також покращено стабільність результатів та зменшено кількість артефактів

9

ВИСНОВКИ

Як результат виконання кваліфікаційної роботи бакалавра було спроектовано та програмно реалізовано метод інтеграції експертних знань у модель глибокого навчання для сегментації МРТ -зображень серця.

Розроблена система демонструє підвищену точність (на 7 складних випадках, покращену стабільність і зменшення артефактів. Результати доводять ефективність поєднання машинного навчання з експертною логікою, що має практичне значення для медицини та потенціал до подальшого розвитку. –10%) у

10

ДЯКУЮ ЗА УВАГУ!

11

Anti-Plagiarism (UA) v-15.281 Educational

The maximum coincidence with one document 3.0%

Dictionary check: en_US, ru_RU, ua_UA. **Errors in the documents: 12%**

ID: 247068 Title: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця Added in a DB: 2025-06-19 Authors: Оксана ГЛОБЧАСТА Heads: Павло РАДЮК Consultants: Opponents:	Document		Sum coincidence on the DB	
	Symbols	Lexemes	Symbols	Lexemes
	64253	969	3364 (5%)	57 (6%)

Plagiarism sources

ID	Description	Plagiarism presence in the document	
		Symbols	Lexemes

Протокол аналізу звіту подібності науковим керівником

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

Автор: Оксана ГЛОБЧАСТА

Співавтор:

Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця

Науковий керівник: Павло РАДЮК, старший викладач кафедри, Ph.D.

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 5.3%

Коефіцієнт подібності 2: 2.4%

Мікропробіли: 0

Заміна букв: 8

Інтервали: 0

Білі знаки: 0

Дата створення звіту: 2025-06-20 03:19:07.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедурам. Таким чином робота не приймається.

Обґрунтування:

2025-06-20

Дата

експерт

І.А. Петровський Р.С.

РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК

ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Назва кваліфікаційної роботи Метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця

Автор студентка групи КН-21-1 Глобчаста Оксана

Освітня програма Комп'ютерні науки

Рівень вищої освіти перший (бакалаврський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: док. фіз., ст. викладач кафедри комп'ютерних наук Павло Радюк

На основі аналізу кваліфікаційної роботи на дотримання вимог академічної доброчесності (у т.ч. відсутності ознак академічного плагіату) з урахуванням результатів перевірки роботи спеціалізованим програмними засобами комісія зробила такий висновок:

№	Висновок	Позначка про відповідність
1	Ознаки академічного плагіату	
1.1	Запозичення, виявлені в роботі, є законними і не є академічним плагіатом (далі – зазначаються підстави віднесення запозичень до правомірних, якщо потрібно). Робота приймається до захисту.	відповідає
1.2	Виявлені запозичення не є академічним плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи (далі – зазначаються детальні та аргументовані підстави віднесення запозичень до правомірних). Робота приймається до захисту, але має бути відкоригована.	
1.3	Виявлені запозичення не є академічним плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота може бути допущена до захисту після того як буде відкоригована та доопрацьована і успішно пройде повторну перевірку на академічний плагіат.	
1.4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття текстових запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	
2	Інші види порушень академічної доброчесності	відсутні

Підтвердження:

Запозичення, що виявлені в роботі Оксани Глобчастої, не є плагіатом, оскільки: знайдені текстові збіги розміщені в розділі огляду наявних підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; до запозичень входять фрагменти, які не мають авторства і містять поширені конструкції та загальновідомі терміни, скорочення. Рівень подібності не перевищує допустимої межі. Отже, робота є законною та приймається до захисту.

Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості:

- за системою Anti-Plagiarism: 3.0%;

- за системою StrikePlagiarism КП1: 5.3%, КП2: 2.4%.

20.06.2025

Завідувач кафедри



Олександр БАРМАК

Гарант освітньої програми



Олександр МАЗУРЕЦЬ

Керівник кваліфікаційної роботи



Павло РАДЮК



ВІДГУК НАУКОВОГО КЕРІВНИКА
на кваліфікаційну роботу бакалавра

студента КН-21-1 Глобчатої Оксани Вячеславівни
за темою Метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця

1. Актуальність теми

Точне сегментування зображень МРТ серця є важливим для діагностування серцево-судинних захворювань. Стандартні моделі глибокого навчання мають технічні та експертні обмеження. Тому проєктування методу, що інтегрує експертні анатомічні знання для підвищення точності автоматичного аналізу, є актуальним завданням, яке має високу практичну цінність для сучасної медицини та біомедичної інженерії.

2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки

Результати кваліфікаційної роботи повністю відповідають стандарту спеціальності 122 Комп'ютерні науки. Студентка спроектувала та реалізувала складну систему, що поєднує методи глибокого навчання, оброблення зображень та інженерію програмного забезпечення. Робота демонструє володіння ключовими об'єктами вивчення та підтверджує успішне засвоєння освітньої програми на високому рівні.

3. Професійні та особистісні якості бакалавра

Студентка Глобчата О. В. проявила себе як дисциплінована та кваліфікована фахівчиня, вчасно та якісно виконавши всі етапи кваліфікаційної роботи. Вона продемонструвала глибоке розуміння предметної області, поєднавши теоретичні знання з практичною реалізацією. Її рівень підготовки, професійні навички та компетентності повністю відповідають кваліфікації бакалавра за спеціальністю 122 Комп'ютерні науки.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Студентка Глобчата О. В. продемонструвала достатній рівень самостійності впродовж усього періоду роботи. Вона самостійно проводила аналіз сучасних рішень, проєктувала метод та архітектуру інформаційної системи за цим методом, реалізовувала вебсервіс за створеним методом та проводила експериментальні дослідження. Це свідчить про її здатність до самостійної науково-дослідницької та проєктної діяльності.

5. Ступінь оволодіння методами дослідження

Під час виконання роботи студентка впевнено застосовувала сучасні методи дослідження. Вона продемонструвала володіння технологіями глибокого навчання (TensorFlow, U-Net), інструментами для оброблення зображень (OpenCV) та створення вебсервісів (Gradio). Це дало їй можливість виконати всі поставлені завдання та досягти мети кваліфікаційної роботи.

6. Повнота та якість розкриття теми роботи

Тема кваліфікаційної роботи розкрита повно та всебічно. Студентка якісно проаналізувала предметну область, детально описала спроектований метод та його програмну реалізацію у вигляді вебсервісу. Усі завдання виконано, а розроблений вебсервіс доводить підвищення точності сегментування МРТ-зображень серця за запропонованим методом. Експериментальні результати підтверджують досягнення мети роботи, що свідчить про високу якість та завершеність проєкту.

7. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

Матеріал кваліфікаційної роботи викладено логічно, послідовно та із чіткою науковою аргументацією. Структура роботи є добре продуманою та повністю відповідає меті дослідження. Текст написаний на високому науковому рівні, з дотриманням стандартів оформлення та академічної доброчесності, що свідчить про високу культуру академічного письма.

8. Можливість практичного застосування кваліфікаційної роботи бакалавра, окремих її частин

Спроектований метод та реалізований вебсервіс мають високу практичну цінність. Вони можуть використовуватися в медичних закладах для підвищення точності діагностування, у наукових дослідженнях для аналізу даних, а також як навчальний інструмент для підготовки майбутніх фахівців у галузі медичної інформатики.

9. Висновок про можливість допуску кваліфікаційної роботи бакалавра до захисту, на яку оцінку заслуговує робота

Кваліфікаційна робота бакалавра Глобчної О. В. є завершеним дослідженням, виконана на достатньому рівні та повністю відповідає всім встановленим вимогам. З огляду на теоретичну обґрунтованість та практичну значущість роботи, вважаю, що робота може бути допущена до захисту. Рекомендована оцінка – «добре».

Керівник _____



док. філ., ст. викл. каф. КН Павло РАДЮК



РЕЦЕНЗІЯ

на кваліфікаційну роботу бакалавра

студента КН-21-1 Глобчастої Оксани Вячеславівни
за темою: Метод інтеграції експертних знань в модель глибокого навчання для сегментування зображень МРТ серця

1. Актуальність обраної теми

Тема роботи є актуальною, оскільки своєчасне та точне діагностування серцевих захворювань є пріоритетом сучасної медицини. Використання глибокого навчання для аналізу МРТ-зображень є перспективним напрямом. Запропонований у роботі метод інтеграції експертних знань дає змогу подолати обмеження стандартних моделей, що робить дослідження важливим як із наукового, так і з практичного погляду.

2. Повнота розкриття мети та завдань роботи

Мета та завдання кваліфікаційної роботи розкрито повністю. Авторка провела аналіз предметної області, спроектувала інноваційний метод, реалізувала його у вигляді інтерактивного вебсервісу та виконала експериментальне дослідження. Результати тестування переконливо доводять, що інтеграція експертних знань підвищує точність сегментування МРТ-зображень серця, що свідчить про досягнення поставленої мети.

3. Зміст кожного розділу роботи

У першому розділі роботи проведено аналіз методів оброблення зображень МРТ серця. Другий розділ присвячено детальному проєктуванню методу інтеграції знань на базі архітектури U-Net та модифікації функції втрат. У третьому розділі описано програмну реалізацію вебсервісу та наведено результати експериментального дослідження, що підтверджують підвищення точності сегментування МРТ-зображень серця.

4. Оцінка розробленого методу та його практична цінність

Спроектований метод є науково обґрунтованим та має високу практичну цінність. Його реалізація у вигляді вебсервісу дає змогу наочно продемонструвати переваги інтеграції експертних знань та може слугувати прототипом для клінічних систем підтримки прийняття рішень. Це може підвищити надійність автоматизованої діагностики та має потенціал для впровадження в медичну практику.

5. Якість оформлення кваліфікаційної роботи бакалавра

Робота оформлена відповідно до встановлених вимог ДСТУ. Вона має чітку логічну структуру, містить усі необхідні елементи, включно з анотацією, висновками, додатками та актуальним переліком посилань. Матеріал викладено послідовно та грамотною науковою мовою. Таблиці та рисунки належно оформлені, що сприяє легкому сприйняттю дослідження.

6. Недоліки кваліфікаційної роботи бакалавра

Попри високу якість роботи, її експериментальна частина має певні недоліки. Зокрема, кількість проведених експериментів є дещо обмеженою, що не забезпечило проведення комплексного порівняння створеного методу з іншими альтернативними підходами до інтеграції знань, окрім базової моделі. Також робота виграла б від глибшого обговорення практичних викликів, пов'язаних з інтеграцією таких систем у реальні клінічні середовища.

7. Загальний висновок (допускається чи не допускається до захисту), та оцінка на яку заслуговує кваліфікаційна робота.

Кваліфікаційна робота є завершеним науково-практичним дослідженням, яке повністю відповідає вимогам до робіт такого рівня. Авторка продемонструвала глибоке розуміння предметної області та володіння сучасними інструментами. Робота заслуговує на позитивну оцінку та може бути допущена до захисту.

Рекомендована оцінка – «добре».

Рецензент Калуштен М. В., к. т. н., доц.

