


## КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА


на тему Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами


Галузь знань 12 – Інформаційні технології  
Шифр і назва галузі знань


Спеціальність 122 – Комп'ютерні науки

Освітня програма Комп'ютерні науки  
Шифр і назва спеціальності

Виконав: студент 2 курсу, група КНм-22-1  В.С. Уваров  
Підпис Ініціали, прізвище

Керівник: д.т.н., професор кафедри КН  Е.А. Манзюк  
Підпис Ініціали, прізвище


Нормоконтроль: к.т.н., доцент кафедри КН  Р.О. Багрій  
Підпис Ініціали, прізвище

До захисту допускаю:  
Зав. кафедри КН, д.т.н., професор  О.В. Бармак  
Підпис Ініціали, прізвище

08 чудня 2023 р.

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

ЗАТВЕРДЖУЮ  
Завідувач кафедри комп'ютерних наук

  
(підпис)  
д.т.н., професор О.В. Бармак

« 1 » вересня 2023 року

### ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ МАГІСТРА

1. Тема кваліфікаційної роботи магістра: Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами
2. Завдання видано студенту Уварову Владиславу Сергійовичу  
(прізвище, ім'я, по батькові)
3. Керівник роботи д.т.н. Манзюк Едуард Андрійович  
(прізвище, ім'я, по батькові)
4. Затверджені наказом університету від « 15 » 08 2023 р. № 30
5. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Мета роботи – розробка методу діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами. Особливістю запропонованого методу є використання загорткової нейронної мережі для покращеного визначення контурів та адаптації до різних розмірів міокарда при локальній деталізації. Удосконалено метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами. Метод спрямований на автоматичну сегментацію міокарда серця на зображеннях, отриманих з використанням МРТ. Важливою запропонованою інновацією є здатність методу аналізувати великі обсяги МРТ-зображень, визначити контур міокарда та точно відобразити його у вигляді контурів на зображенні.

## Реферат

Кваліфікаційна робота магістра розв'язує науково-практичну задачу розробки метода діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами. Особливістю запропонованого методу є використання загорткової нейронної мережі для покращеного визначення контурів та адаптації до різних розмірів міокарда при локальній деталізації.

**Актуальність теми.** Серцево-судинні захворювання протягом багатьох років залишаються провідною причиною смерті у всьому світі, особливо в розвинених країнах, підкреслюючи важливість сфери охорони здоров'я. У цьому контексті визначення стану та функцій серця через методи візуалізації, такі як ультразвукове дослідження, електрокардіографія і магнітно-резонансна томографія, відіграє критичну роль в точній діагностиці.

Об'єктивні та ефективні засоби аналізу функціонування серця є важливим елементом цього завдання. Зокрема, визначення об'єму лівого шлуночка серця є ключовим для виявлення можливого збільшення серця внаслідок серцевої недостатності. Лівий шлуночок, відповідальний за перекачування крові, є вирішальним для загальної оцінки роботи серця. Наукові дослідження в цьому напрямку спрямовані на аналіз образів серця, отриманих з використанням МРТ.

У медицині засоби візуалізації є ключовими для точної та своєчасної діагностики серцевих та судинних захворювань. В цьому контексті існують різноманітні методи візуалізації, такі як ультразвукове дослідження, електрокардіографія та магнітно-резонансна томографія, які відіграють важливу роль у процесі діагностики та моніторингу стану серця та судин.

Експертиза функції серця виявляє свої унікальні аспекти, з визначенням об'єму лівого шлуночка серця як ключовим завданням, оскільки його збільшення може слугувати індикатором розвитку серцевої недостатності. Лівий шлуночок, відповідальний за ефективне перекачування крові, становить основний об'єкт аналізу, що надає визначення його функціонального стану і розкриває важливі аспекти загального функціонування серця.

Сучасні наукові дослідження в галузі кардіології націлені на систематичне удосконалення методів аналізу зображень серця, отриманих завдяки технології магнітно-резонансної томографії (МРТ). Ці дослідження, поглиблюючи розуміння механізмів функціонування серця, сприяють розробці нових методів діагностики та лікування серцевих захворювань. Такий підхід відкриває перспективи для підвищення ефективності медичної допомоги пацієнтам із серцевими патологіями.

Потреба у вдосконаленні точності та ефективності діагностики серцевих захворювань викликає необхідність подальших досліджень у сфері використання нейромереж для аналізу та інтерпретації зображень МРТ. Цей напрямок досліджень може відкрити нові можливості для точної та ранньої діагностики, покращуючи якість медичної допомоги пацієнтам із захворюваннями серця.

**Мета і задачі роботи.** Метою кваліфікаційної роботи є вирішення науково-практичної задачі, розробки ефективного методу діагностики захворювань серця, заснованого на аналізі зображень отриманих з магнітно-резонансної томографії, використовуючи загорткову нейронну мережу для кращого визначення контурів та успішної адаптації до різних розмірів міокарда при локальній деталізації.

Такий підхід не лише надає можливість отримувати більш точні результати діагностики, але і враховує унікальні властивості зображень МРТ, які можуть виявлятися змінними та комплексними у різних клінічних випадках. Використання нейромережі для аналізу даних МРТ підвищує загальну надійність та чутливість методу, що робить його ефективним інструментом у сфері вдосконалення серцево-судинної діагностики та подальшого розвитку методів лікування серцевих захворювань.

Завдання дослідження магістерської роботи:

1. Провести огляд наукових досліджень та публікацій в галузі діагностики захворювань серця, зосередженого на аналізі зображень з магнітно-резонансної томографії та використанні передових нейромережевих технологій.

2. Розробити метод автоматизованої діагностики серцевих захворювань, що включає вдосконалене визначення контурів та адаптацію до різних розмірів міокарда через застосування нейромереж.

3. Адаптувати розроблений метод до різних розмірів міокарда, фокусуючись на локальній деталізації та враховуючи варіабельність зображень отриманих з магнітно-резонансної томографії.

4. Провести експериментальні випробування для оцінки ефективності та точності розробленого методу діагностики захворювань серця, використовуючи магнітно-резонансну томографію.

**Об'єкт дослідження** – процес навчання нейронних мереж для визначення контурів міокарда.

**Предмет дослідження** – алгоритми, методи, інструментарій та засоби навчання нейронних мереж для визначення контурів міокарда.

**Методи дослідження**, які використано для вирішення поставлених завдань – інтелектуальний аналіз даних, проектування систем штучного інтелекту, моделі глибокого навчання, згорткові нейронні мережі.

**Наукова новизна одержаних результатів** полягає в тому, що було удосконалено метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами, спрямований на автоматичну сегментацію міокарда серця на зображеннях, отриманих з використанням магнітно-резонансної томографії. Важливою інновацією є здатність системи аналізувати великі обсяги МРТ-зображень, визначати контур міокарда та точно відображати його у вигляді визначених контурів на зображенні. Цей підхід визначається високою точністю та ефективністю сегментації, що відкриває нові перспективи для автоматизованої та точної діагностики серцевих захворювань за допомогою неінвазивних методів зображення, таких як МРТ. Результати дослідження сприяють покращенню точності та швидкості виявлення патологій серця.

**Практичне значення одержаних результатів.** Отримана глибока навчальна модель може слугувати потужним інструментом для швидкого та

автоматизованого визначення стану серця пацієнта. Автоматична сегментація дозволяє точно визначити контури міокарда, що є важливим для діагностики серцевих захворювань та визначення їхнього ступеня тяжкості.

Практичне застосування цієї моделі також проявляється у підтримці клініцистів та медичного персоналу. Вона може значно полегшити їхню роботу, забезпечуючи швидко та об'єктивну інформацію щодо структури серця. Це важливо при прийнятті рішень щодо лікування, визначенні та моніторингу хронічних серцевих захворювань.

Крім того, модель може знайти застосування в дослідженнях та наукових дослідженнях у галузі кардіології, допомагаючи розширювати знання про структуру та функцію серця. Такі дані можуть бути корисні для подальших вдосконалень у лікуванні та профілактиці серцевих захворювань.

Отже, практичне значення цієї моделі виявляється в покращенні точності діагностики, спрощенні роботи медичного персоналу та сприянні розвитку наукових досліджень у галузі кардіології.

**Апробація результатів кваліфікаційної роботи магістра та публікації**  
Одержані наукові і практичні результати кваліфікаційної роботи магістра доповідались в доповіді на тему «Метод діагностики захворювань серця на основі аналізу зображень, отриманих методом магнітно-резонансної томографії» на XV Всеукраїнській науково-практичній конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» (17-18 листопада 2023 року); за темою роботи автором виконано наукову публікацію: Уваров В.С., Чабан О.Р., Манзюк Е.А. Метод діагностики захворювань серця на основі аналізу зображень, отриманих методом магнітно-резонансної томографії. Збірник наукових праць за матеріалами XV Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» Хмельницький, 2023. с. 296-299.

**Структура і обсяг роботи.** Кваліфікаційна робота магістра складається з наступного: реферату, завдання, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань з 46 найменування й 2-х додатків. Загальний обсяг кваліфікаційної роботи магістра становить 98 сторінок, із них 79 сторінок

основного тексту й 12 сторінок додатків. В роботі наведено 14 рисунків й 2 таблиць.

**Ключові слова:** сегментація міокарда, магнітно-резонансна томографія, глибоке навчання, нейромережеві технології, автоматична діагностика серця, точність сегментації, клінічна кардіологія, телемедицина, медична освіта, вдосконалення діагностики серцевих захворювань.

## Зміст

Вступ.....	4
Розділ 1. Огляд систем діагностики захворювань серця за аналізом зображень ...	8
1.1 Аналіз предметної області діагностування хвороб серця.....	8
1.2 Методи діагностування хвороб серця.....	10
1.3 Обробка зображень нейронними мережами .....	12
1.4 Використання загорткових нейронних мереж для семантичної сегментації	15
Постановка задачі.....	16
Висновки до розділу 1 .....	17
Розділ 2. Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами.....	18
2.1 Навчання нейронних загорткових мереж .....	18
2.2 Функції глибокої згорткової нейронної мережі для діагностування хвороб серця .....	20
2.3 Застосування згорткового фільтра в нейронній мережі.....	21
2.4 Функція активації та пакетна нормалізація.....	22
2.5 Структура глибокої загорткової нейронної мережі.....	31
2.6 Мережева архітектура загорткової мережі.....	37
2.7 Схема навчання загорткової мережі .....	39
Висновки до розділу 2 .....	40
Розділ 3 Адаптація моделі та застосування до множини даних.....	41
3.1 Набори даних зображень серця на основі магніто-резонансних досліджень	41
3.2 Формат даних зображень серця.....	43
3.3 Сегментація зображень магніто-резонансного аналізу.....	50
Висновки до розділу 3 .....	57
Розділ 4. Експериментальні дослідження ефективності діагностики захворювань серця за аналізом зображень .....	58
4.1 Ефективність мереж, навчених на наборах даних.....	58
4.2 Формування сегментованих контурів .....	61
4.3 Оцінювання втрат при навчанні моделей.....	66
Висновки до розділу 4 .....	70

	3
Загальні висновки.....	72
Перелік посилань.....	74
Додатки.....	80

## Вступ

Кваліфікаційна робота магістра розв'язує науково-практичну задачу розробка метода діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами. Особливістю запропонованого методу є використання загорткової нейронної мережі для покращеного визначення контурів та адаптації до різних розмірів міокарда при локальній деталізації.

**Актуальність теми.** Серцево-судинні захворювання протягом багатьох років залишаються провідною причиною смерті у всьому світі, особливо в розвинених країнах, підкреслюючи важливість сфери охорони здоров'я. У цьому контексті визначення стану та функцій серця через методи візуалізації, такі як ультразвукове дослідження, електрокардіографія і магнітно-резонансна томографія, відіграє критичну роль в точній діагностиці. Об'єктивні та ефективні засоби аналізу функціонування серця є важливим елементом цього завдання. Зокрема, визначення об'єму лівого шлуночка серця є ключовим для виявлення можливого збільшення серця внаслідок серцевої недостатності. Лівий шлуночок, відповідальний за перекачування крові, є вирішальним для загальної оцінки роботи серця. Наукові дослідження в цьому напрямку спрямовані на аналіз образів серця, отриманих з використанням МРТ.

У медицині засоби візуалізації визнаються ключовими для точної та своєчасної діагностики серцевих та судинних захворювань. В цьому контексті існують різноманітні методи візуалізації, такі як ультразвукове дослідження, електрокардіографія та магнітно-резонансна томографія, які відіграють важливу роль у процесі діагностики та моніторингу стану серця та судин. Експертиза функції серця виявляє свої унікальні аспекти, з визначенням об'єму лівого шлуночка серця як ключовим завданням, оскільки його збільшення може слугувати індикатором розвитку серцевої недостатності. Лівий шлуночок, відповідальний за ефективне перекачування крові, становить основний об'єкт аналізу, що надає визначення його функціонального стану і розкриває важливі аспекти загального функціонування серця.

Сучасні наукові дослідження в галузі кардіології націлені на систематичне удосконалення методів аналізу зображень серця, отриманих завдяки технології магнітно-резонансної томографії (МРТ). Ці дослідження, поглиблюючи розуміння механізмів функціонування серця, сприяють розробці методів діагностики та лікування серцевих захворювань. Такий підхід відкриває перспективи для підвищення ефективності медичної допомоги пацієнтам із серцевими патологіями.

Потреба у вдосконаленні точності та ефективності діагностики серцевих захворювань викликає необхідність подальших досліджень у сфері використання нейромереж для аналізу та інтерпретації зображень МРТ. Цей напрямок досліджень може відкрити нові можливості для точної та ранньої діагностики, покращуючи якість медичної допомоги пацієнтам із захворюваннями серця.

**Мета і задачі роботи.** Метою кваліфікаційної роботи є вирішення науково-практичної задачі, яка стосується розробки ефективного методу діагностики захворювань серця, заснованого на аналізі зображень отриманих з магнітно-резонансної томографії, використовуючи загорткову нейронну мережу для поліпшеного визначення контурів та успішної адаптації до різних розмірів міокарда при локальній деталізації. Такий підхід не лише надає можливість отримувати більш точні результати діагностики, але і враховує унікальні властивості зображень МРТ, які можуть виявлятися змінними та комплексними у різних клінічних випадках. Використання нейромережі для аналізу даних МРТ підвищує загальну надійність та чутливість методу, що робить його ефективним інструментом у сфері вдосконалення серцево-судинної діагностики та подальшого розвитку методів лікування серцевих захворювань.

Завдання дослідження магістерської роботи.

1. Провести огляд наукових досліджень та публікацій в галузі діагностики захворювань серця, зосередженого на аналізі зображень з магнітно-резонансної томографії та використанні передових нейромережевих технологій.

2. Розробити метод автоматизованої діагностики серцевих захворювань, що включає вдосконалене визначення контурів та адаптацію до різних розмірів міокарда через застосування нейромереж.

3. Адаптувати розроблений метод до різних розмірів міокарда, фокусуючись на локальній деталізації та враховуючи варіабельність зображень отриманих з магнітно-резонансної томографії.

4. Провести експериментальні випробування для оцінки ефективності та точності розробленого методу діагностики захворювань серця, використовуючи магнітно-резонансну томографію.

**Об'єкт дослідження** – процес навчання нейронних мереж для визначення контурів міокарда.

**Предмет дослідження** – алгоритми, методи, інструментарій та засоби навчання нейронних мереж для визначення контурів міокарда.

**Методи дослідження**, які використано для вирішення поставлених завдань – інтелектуальний аналіз даних, проектування систем штучного інтелекту, глибокі нейронні мережі, згорткові нейронні мережі.

**Наукова новизна одержаних результатів** полягає в удосконаленні методу діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами, спрямований на автоматичну сегментацію міокарда серця на зображеннях, отриманих з використанням магнітно-резонансної томографії. Важливою інновацією є здатність методу аналізувати великі обсяги МРТ-зображень, визначати контур міокарда та точно відобразити його у вигляді визначених контурів на зображенні. Цей підхід визначається високою точністю та ефективністю сегментації, що відкриває нові перспективи для автоматизованої та точної діагностики серцевих захворювань за допомогою неінвазивних методів зображення, таких як МРТ.

**Практичне значення одержаних результатів.** Отримана глибока навчальна модель може слугувати потужним інструментом для швидкого та автоматизованого визначення стану серця пацієнта. Автоматична сегментація дозволяє точно визначити контури міокарда, що є важливим для діагностики

серцевих захворювань та визначення їхнього ступеня тяжкості. Практичне застосування цієї моделі також проявляється у підтримці клініцистів та медичного персоналу. Вона може значно полегшити їхню роботу, забезпечуючи швидку та об'єктивну інформацію щодо структури серця. Це важливо при прийнятті рішень щодо лікування, визначенні та моніторингу хронічних серцевих захворювань. Крім того, модель може знайти застосування в дослідженнях та наукових дослідженнях у галузі кардіології, допомагаючи розширювати знання про структуру та функцію серця. Отже, практичне значення цієї моделі виявляється в покращенні точності діагностики, спрощенні роботи медичного персоналу та сприянні розвитку наукових досліджень у галузі кардіології.

**Апробація результатів кваліфікаційної роботи магістра та публікації**  
Одержані наукові і практичні результати кваліфікаційної роботи магістра доповідались в доповіді на тему «Метод діагностики захворювань серця на основі аналізу зображень, отриманих методом магнітно-резонансної томографії» на XV Всеукраїнській науково-практичній конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» (17-18 листопада 2023 року); за темою роботи автором виконано наукову публікацію: Уваров В.С., Чабан О.Р., Манзюк Е.А. Метод діагностики захворювань серця на основі аналізу зображень, отриманих методом магнітно-резонансної томографії. Збірник наукових праць за матеріалами XV Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» Хмельницький, 2023. с. 296-299.

**Структура і обсяг роботи.** Кваліфікаційна робота магістра складається з наступного: реферату, завдання, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань з 46 найменування й 2-х додатків. Загальний обсяг кваліфікаційної роботи магістра становить 98 сторінок, із них 79 сторінок основного тексту й 12 сторінок додатків. В роботі наведено 14 рисунків й 2 таблиць.

## **Розділ 1. Огляд систем діагностики захворювань серця за аналізом зображень**

### **1.1 Аналіз предметної області діагностування хвороб серця**

Серцево-судинні захворювання вже багато років є провідною причиною смерті у всьому світі [8, 40, 41, 44]. У сучасному світі, зокрема в розвинених країнах, це питання має важливе значення для сфери охорони здоров'я. У цьому контексті велике значення надається методам візуалізації, які грають важливу роль в наданні точного діагнозу вчасно. Для визначення стану серця та його функції використовуються різні методи візуалізації, такі як ультразвукове дослідження, електрокардіографія і магнітно-резонансна томографія (МРТ) [3, 12, 26, 45].

Ці методи вимагають об'єктивних і ефективних засобів аналізу функціонування серця. Зокрема, важливим завданням є визначення об'єму лівого шлуночка серця, що дозволяє виявити можливе збільшення серця внаслідок серцевої недостатності. Лівий шлуночок відповідає за перекачування крові до більшої частини організму, роблячи його функцію вирішальною для загальної оцінки роботи серця. Наукові дослідження, проведені в цій галузі, спрямовані на аналіз образів серця, які отримані за допомогою МРТ.

Засоби візуалізації виявляються значущими у медицині для точної та вчасної діагностики серця та судин. У цьому аспекті, існують різні методи візуалізації, такі як ультразвукове дослідження, електрокардіографія та магнітно-резонансна томографія, які грають ключову роль у цьому процесі [10, 19, 25, 32].

Оцінка функції серця має свої особливості, і однією з важливих задач є визначення об'єму лівого шлуночка серця. Це важливо, оскільки збільшення лівого шлуночка може свідчити про розвиток серцевої недостатності. Лівий шлуночок відповідає за перекачування крові до більшої частини організму, і саме тому визначення його функції має вирішальне значення для оцінки стану серця.

Наукові дослідження в цій галузі спрямовані на покращення аналізу зображень серця, отриманих завдяки МРТ. Ці дослідження сприяють розширенню наших знань про функціонування серця і розвитку нових методів діагностики та лікування серцевих захворювань, що надає перспективи на покращення якості медичної допомоги пацієнтам з серцевими проблемами.

Під час проведення МРТ серця отримують тривимірні зображення шляхом сканування тіла та виділення різних зрізів серця [22, 36, 38]. Ці зрізи розділяються на три типи: базальні, які відображають верхню частину серця, середньошлуночкові, що представляють середню частину серця, і апікальні, що відображають нижню частину серця [6].

Оцінка об'єму лівого шлуночка проводиться на двох етапах серцевого циклу: наприкінці скорочення, кінцевий систолічний об'єм та безпосередньо перед скороченням, кінцевий діастолічний об'єм. Важливо відзначити, що форма та товщина стінок лівого шлуночка відрізняються на цих двох етапах. Приклад виділеного зрізу серця показано на рисунку 1.1.




Рисунок 1.1 – Ілюстрація зображення МРТ серця [29]

У момент завершення скорочення серця лівий шлуночок стає грубішим через м'язову компресію (міокарда), а наприкінці діастолі лівий шлуночок знову стає тоншим, оскільки кров починає входити в нього.

Отримані об'єми дозволяють лікарям оцінити функцію серця за важливими параметрами, такими як ударний об'єм, кількість крові, яку серце перекачує протягом одного циклу, серцевий викид, кількість крові, яку викидає серце під час скорочення і фракція викиду.

Для визначення об'єму лівого шлуночка та інших показників функції серця необхідно точно визначити контур ендокарда, який представляє внутрішню стінку міокарда. При аналізі деформації міокарда та інших характеристик також необхідно враховувати контур епікарда, що визначає зовнішню стінку міокарда. Один з поширених методів виділення контуру епікарда полягає в ручному малюванні його на кожному зрізі для обох часових інтервалів. Проте ручне викреслювання контурів є довгим процесом і вимагає від експерта спеціальних навичок і знань. І саме тому в останні роки все більше використовують автоматизовані методи, які дозволяють значно полегшити цей процес.

## **1.2 Методи діагностування хвороб серця**

Традиційні методи аналізу зображень стикаються з обмеженнями при сегментації зображень. Вони вимагають великої кількості досвіду та часу для налагодження та роботи на нових завданнях сегментації. Кожна нова задача потребує свого власного алгоритму, що ускладнює процес розробки. Машинне навчання надає значно більшу універсальність в розв'язанні завдань сегментації зображень [31]. За допомогою машинного навчання, алгоритм може навчитися розпізнавати об'єкти на зображеннях на основі наявних даних, таких як зображення з уже відомою сегментацією [1, 21, 33, 34].

Однак, однією з важливих умов для успішної роботи машинного навчання є наявність великої кількості даних з правильною сегментацією. Проте розроблені методи дозволяють ефективно працювати з меншою кількістю даних.

Використання глибокого навчання в аналізі зображень стало дуже популярним завдяки обчислювальній потужності і доступності великої кількості

даних [42]. Глибоке навчання виявилось потужним інструментом для сегментації та класифікації об'єктів на зображеннях [5, 37, 46]. Воно відкрило нові можливості в багатьох галузях застосування, включаючи обробку зображень в тому числі отриманих в медичній сфері.

Використання машинного навчання та глибокого навчання для розуміння зображень і сцен стало домінуючим напрямком розвитку протягом останнього десятиліття і виявилось потужним інструментом для аналізу зображень. Існує кілька важливих факторів, що сприяють цій популярності, зокрема, доступ до великих обчислювальних потужностей та обсягів даних.

Забезпечення обчислювальної потужності досягається завдяки використанню графічних процесорів, які здатні паралельно виконувати велику кількість обчислень з високою швидкістю. Це дозволяє навчальним алгоритмам працювати швидше та ефективніше.

Глибоке навчання активно розвивається і продемонструвало хороші результати в багатьох сферах застосування. Воно значно вдосконалило автоматичну сегментацію та класифікацію об'єктів на зображеннях та виявило велику універсальність порівняно з традиційними методами. Одним з важливих застосунків, що отримав велику увагу, є обробка зображень трасових сцен. У цьому контексті для успішної навігації комп'ютера необхідно ефективно сегментувати та класифікувати об'єкти. Метою цього дослідження є створення глибокої навчальної моделі для автоматичної сегментації міокарда лівого шлуночка серця на зображеннях, отриманих за допомогою магнітно-резонансної томографії. Основною задачею є створення системи, яка, аналізуючи вхідні зображення, здатна виділити контур міокарда та подати його у вигляді намальованих контурів на зображенні. Цей проєкт став можливим завдяки доступності великого обсягу МРТ-зображень серця.

Виходячи з припущення, що інструменти машинного навчання досить розвинені, цей проєкт призначений для користувачів, які не мають значного досвіду в галузі машинного навчання. Він вписується в контекст автоматизації

процесу діагностування на основі МРТ-зображень серця з використанням глибокого навчання.

Завдання включають розробку системи для автоматичної сегментації міокарда на МРТ-зображеннях з використанням глибокого навчання, дослідження абстрактних концепцій, таких як уникнення класифікації темних плям у лівому шлуночку як міокарда, знаходження методів оцінювання, придатних з медичної точки зору, визначення впливу розміру набору даних та оцінку ефективності розробленої системи для автоматизованої діагностики серцевих захворювань.

### **1.3 Обробка зображень нейронними мережами**

Основним принципом обробки зображень є виявлення відповідних закономірностей, які розкривають зміст зображення [17, 20, 39]. Ці закономірності називаються ознаками. Обробка зображень включає в себе вилучення цих ознак із зображення і їх подальше використання для отримання інформації про контент зображення, як визначення об'єктів, наприклад, собака, пейзаж, ніч або день тощо. Процес виділення ознак може бути виконаний вручну, де програміст визначає, які ознаки є важливими для конкретної задачі. Однак важливо мати повне уявлення про всі релевантні ознаки та їх взаємозв'язок.

Замість того, щоб розглядати алгоритми, що базуються на попередніх знаннях, які програміст має надавати, машинне навчання намагається витягти ці ознаки, аналізуючи закономірності в даних. Суть полягає в тому, щоб алгоритм зміг визначити власні ознаки та їх важливість одна для одної на основі наданих даних. Це, в сутності, є ідеєю, що лежить в основі машинного навчання.

Іноді у завданнях класифікації зображень потрібно визначити більше одного об'єкта на зображенні [4, 7, 24, 27, 30]. Це досягається, виділяючи області інтересу або обмежувальні рамки навколо окремих об'єктів на зображенні і надаючи кожному об'єкту відповідний клас, такий як собака або дерево. Цей

процес визначення контурів навколо різних об'єктів на зображенні відомий як сегментація зображень. У розглянутому випадку це означає виділення міокарда на МРТ-знімку серця від решти частини зображення, яка не належить міокарду.

Існує велика кількість наукових досліджень, які детально розглядають різні концепції, і важливо вивчити їх докладніше. Надамо загальне уявлення про концепції, щоб зробити їх зрозумілими, і продемонструємо їх застосування на прикладі сегментації зображень, що є об'єктом цього проекту. Штучний інтелект охоплює різні напрямки, спрямовані на розробку комп'ютерів і алгоритмів, що володіють інтелектуальними здатностями. Машинне навчання входить у цю область і є інструментом ШІ. Воно передбачає створення алгоритмів, які використовують дані для прогнозування та навчання на основі цих прогнозів з метою поліпшення процесу прийняття рішень. Машинне навчання можна порівняти з природним навчанням, коли людина і розумний організм прогнозують реакцію на певну ситуацію і навчаються реагувати краще в майбутньому на основі отриманих знань.

Машинне навчання передбачає визначення оптимального результату та створення методів для досягнення цього результату. У випадку сегментації зображень, машинне навчання дозволяє створювати алгоритми, які виділяють ознаки на зображеннях та призначають класи пікселям на основі цих ознак. Алгоритм визначає, до якого класу належить кожен піксель зображення, спираючись на його ознаки та прогнози. Навчальний процес включає в себе оптимізацію виділення ознак та процесу прийняття рішень, в якому алгоритм постійно оновлює свої параметри, намагаючись наблизитися до оптимального рішення. В рамках машинного навчання існує декілька підходів до створення прогнозів та навчання алгоритмів на основі даних. Один із таких підходів полягає в розробці алгоритмів, інспірованих нейронами мозку, і відомих як штучні нейронні мережі. Ці мережі складаються з великої кількості нейронів, які обробляють вхідні дані, активуються в залежності від цих даних та генерують вихідний сигнал на основі активації. Штучні нейронні мережі мають структуру,

де вхідний сигнал проходить через нейрони та пов'язані з ними зв'язки, і ця обробка даних призводить до формування кінцевого результату.

Архітектури алгоритмів машинного навчання можна представити у вигляді графа, де компоненти пов'язані один з одним. Наприклад, у штучних нейронних мережах ці компоненти відомі як шари. Глибоке навчання виникає, коли ці шари розташовані один за одним. Кожен шар приймає активації вище розташованого шару, і кожен шар формує нове представлення даних. Це дозволяє алгоритму вивчати складніші концепції та розділяти прості та складні ознаки. Наприклад, перший шар може виділяти краї зображення, які наступний шар використовує для визначення кутів та контурів об'єктів на зображенні. Далі, шари можуть вивчити форму, розмір, поворот об'єкта і навіть визначити, як повинен виглядати цей об'єкт.




Рисунок 1.2 – Зв'язок між штучним інтелектом, машинним навчання, глибоким навчанням

ШІ є широким колом наукових інтересів, об'єднуючи різні галузі, і однією з найважливіших є машинне навчання. Машинне навчання – галузь інформатики, що дозволяє комп'ютерам навчатися розв'язувати завдання без необхідності явного програмування. Глибоке навчання представляє собою підгалузь машинного навчання, засновану переважно на використанні штучних нейронних мереж.

## 1.4 Використання загорткових нейронних мереж для семантичної сегментації

Застосування згорткових нейронних мереж для завдань семантичної сегментації, тобто розділення пікселів зображення на різні класи, вивчалось дослідницькими групами у різних контекстах [9, 16, 35]. Багато з цих досліджень базувалися на використанні загальнодоступних наборів даних, таких як Kaggle, і надавали основний акцент на розробку згорткових мереж. Зазвичай вони використовували знання, накопичені в галузі класифікації зображень, і часто використовували попередньо навчені мережі, які були навчені на великих наборах даних із маркованими зображеннями [14]. Особливий інтерес становила сегментація медичних зображень за допомогою глибокого навчання [2, 15, 18, 28, 43]. Ці дослідження також базувалися на доступних наборах даних, але вони зазвичай були меншими, оскільки отримання добре позначених медичних даних є більш складною задачею [23]. Часто основний акцент робився на технічних досягненнях у глибокому навчанні, іноді не надаючи належної уваги розумінню принципів роботи цих мереж, що може бути важливим для їхнього застосування в клінічних умовах.

У деяких дослідженнях використовується 3D-сегментація, в якій враховується повна тривимірна інформація зображення [11]. Ця інформація часто використовується під час ручної сегментації, і можливо використовувати її для навчання нейронних мереж [13]. Один з відомих підходів передбачає використання системи, яка включає кілька глибоких нейронних мереж і полярне представлення зображень для виділення контуру міокарда на МРТ-зображеннях. У цій роботі для отримання набору точок контуру навколо ендо- та епікарда використовувалася регресія, замість класифікації пікселів. Додатково використовується перетворення Фур'є зрізів зображення під час серцевого циклу, що надає інформацію про рух серця під час цього циклу.

## Постановка задачі

Мета даної кваліфікаційної роботи полягає у вирішенні науково-практичної задачі, спрямованої на розробку ефективного методу діагностики серцевих захворювань. Цей метод ґрунтується на аналізі зображень, отриманих за допомогою магнітно-резонансної томографії, і використовує загорткову нейронну мережу для поліпшення визначення контурів та успішної адаптації до різних розмірів міокарда при локальній деталізації.

Такий підхід не лише гарантує отримання точних результатів діагностики, але також враховує унікальні властивості зображень МРТ, які можуть змінюватися та бути складними у різних клінічних випадках. Застосування нейромережі для аналізу даних МРТ підвищує загальну надійність та чутливість методу, роблячи його ефективним інструментом для удосконалення діагностики серцево-судинних захворювань та розвитку нових методів лікування.

Завдання дослідження магістерської роботи:

1. Провести огляд наукових досліджень та публікацій в галузі діагностики захворювань серця, зосередженого на аналізі зображень з магнітно-резонансної томографії та використанні передових нейромережевих технологій.
2. Розробити метод автоматизованої діагностики серцевих захворювань, що включає вдосконалене визначення контурів та адаптацію до різних розмірів міокарда через застосування нейромереж.
3. Адаптувати розроблений метод до різних розмірів міокарда, фокусуючись на локальній деталізації та враховуючи варіабельність зображень отриманих з магнітно-резонансної томографії.
4. Провести експериментальні випробування для оцінки ефективності та точності розробленого методу діагностики захворювань серця, використовуючи магнітно-резонансну томографію.

Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами має бути реалізований через використання

загорткових нейронних мереж для автоматичного визначення контурів та адаптації до різних розмірів міокарда. Цей метод ставить за мету отримати більш точні та чутливі результати діагностики, враховуючи унікальні особливості зображень МРТ в різних клінічних сценаріях, і сприяти ефективному удосконаленню процесу виявлення та лікування серцевих захворювань.

## **Висновки до розділу 1**

У розділі було розглянуто та описано загальний контекст та мету кваліфікаційної роботи, яка спрямована на розробку методу діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами. За допомогою обґрунтування актуальності проблеми серцево-судинних захворювань та визначення основних завдань дослідження, було підкреслено необхідність розвитку ефективних методів діагностики для поліпшення клінічної практики та результатів лікування. У цьому контексті використання нейромережових технологій та аналізу зображень з МРТ стає багатообіцяючим напрямком, що може значно покращити точність та чутливість діагностики серцевих захворювань. У розділі представлено основні аспекти дослідження та визначає основні цілі та завдання, що будуть детальніше розглянуті та розвинуті в подальших розділах роботи. Проаналізовано основні тенденції та проблематику в галузі дослідження, пов'язану з розробкою методу діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами. Розглянуто актуальні аспекти в області обробки зображень та застосування нейромереж для вдосконалення точності та чутливості діагностики серцевих патологій. Визначено проблеми, які є об'єктом подальшого дослідження, та сформульовано завдання для вирішення в рамках даної кваліфікаційної роботи. Аналіз свідчить про важливість та актуальність обраного напрямку дослідження в контексті поліпшення діагностики та лікування серцевих захворювань.

## Розділ 2. Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами

### 2.1 Навчання нейронних загорткових мереж

Необхідно розглянути поняття "навчання" в контексті глибокого навчання. У визначенні вказується, що комп'ютерна програма вважається "навченою" на досвіді  $E$  з вирішення певного класу завдань  $T$ , якщо її продуктивність в розв'язуванні завдань з  $T$ , яка вимірюється за допомогою міри  $R$ , покращується завдяки досвіду  $E$ . У проєкті  $T$  визначається як завдання виділення контуру міокарда,  $R$  - як ступінь відповідності передбаченого контуру реальному, а  $E$  - як оновлення моделі для поліпшення окреслення.

Процес навчання полягає в оптимізації функції втрат, яка контролюється параметрами моделі, відомої як параметри, що навчаються, які були описані раніше для кожного шару.

Оптимізація функції втрат відіграє ключову роль в глибокому навчанні і призводить до збільшення точності прогнозу та адаптації моделі до нових даних. Цей процес включає в себе оновлення параметрів моделі для кожного пакета зображень, які проходять через мережу.

Операцію оновлення параметрів мережі в глибокому навчанні часто називають зворотним поширенням. Основний метод оптимізації, який широко використовується в глибокому навчанні, – це стохастичний градієнтний спуск, і він також застосовується в цьому проєкті. Градієнт функції втрат, який можна розглядати як нахил функції, обчислюється відносно параметрів мережі для кожної партії даних.

У математичному плані оновлення параметра  $\theta$  виконується за допомогою градієнта функції втрат  $L$  та швидкості навчання. Це означає, що при крутому нахилі функції втрат робиться більший крок, і навпаки. Налаштування швидкості навчання – важливий аспект процесу навчання. Це один із гіперпараметрів, параметри, які не навчаються моделлю і зазвичай

налаштовуються вручну, і важливо вибрати його правильно для успішного навчання.

Зазвичай на початку навчання швидкість навчання встановлюється високою, а згодом поступово знижується, оскільки це дозволяє ефективніше навчати модель. Процес контролю швидкості навчання та її зниження є складним завданням, і не існує універсального методу для вибору та налаштування швидкості навчання. Зазвичай рішення з цього питання приймають, спостерігаючи за динамікою функції втрат під час навчання та враховуючи результати на практиці.

Вибір та налаштування гіперпараметрів під час навчання нейронних мереж – це завдання, яке часто потребує великих зусиль і включає в себе ітеративний процес експериментів. Один з методів для підбору оптимальних гіперпараметрів – це використання байєсівської оптимізації.

Цей підхід передбачає навчання нейронної мережі з різними комбінаціями гіперпараметрів з метою знаходження найкращого набору параметрів для конкретного завдання. Оскільки це процес проб і помилок, він може забрати значний час.

Важливо розуміти, що процес навчання нейронних мереж ґрунтується на даних, які використовуються для навчання. Модель може навчатися лише на тих концепціях, які представлені у навчальних даних. Наприклад, для використання глибокого навчання в задачах візуального розпізнавання, потрібно мати великий набір зображень, які містять позначені об'єкти. Ці дані використовуються для навчання моделі розпізнавати певні об'єкти на зображеннях.

Коли задача полягає в сегментації міокарда, необхідність в великому обсязі даних не є настільки великою, оскільки об'єкт на кожному зображенні має схожий характер. Тому для даного завдання можуть знадобитися менші набори даних, порівняно з завданнями загального візуального розпізнавання.

Використання обмеженого обсягу даних може призвести до перенавчання, коли модель стає вкрай спеціалізованою на навчальних даних і не здатна коректно абстрагувати загальні концепції. У такому випадку, модель

може виявляти високу точність лише на навчальних зображеннях, не здатна до загальної сегментації міокарда.

Проте, існують дослідницькі підходи та методи, які допомагають створити точні моделі навіть на обмеженому обсязі даних. Деякі з цих методів включають в себе використання спеціалізованих архітектур мереж, таких як мережі з пакетною нормалізацією, а також методи розширення даних. Розширення даних полягає у створенні нових версій існуючих даних шляхом застосування різних перетворень, таких як зміни масштабу, повороти, деформації та інші. Це дозволяє поповнити набір даних і покращити здатність моделі до узагальнення на нові дані.

Якщо розширення даних включає в себе параметри, які можуть існувати на реальних зображеннях, то модель стає менш чутливою до таких параметрів, як розмір і поворот об'єкта, і набуває загальнішої придатності.

Проте важливо пам'ятати, що навчальний набір повинен відповідати реальному використанню моделі, і немає сенсу додавати до нього зображення, які модель ніколи не зустрине у реальному світі. Це може призвести до створення менш спеціалізованої моделі, без реальних вигравів у продуктивності.

На практиці, процес навчання включає в себе подачу зображень з навчального набору через мережу та багаторазове оновлення параметрів з метою досягнення мінімуму функції втрат, що гарантує хорошу продуктивність моделі. Кожен прохід через весь навчальний набір відомий як одна епоха.

## **2.2 Функції глибокої згортковій нейронній мережі для діагностування хвороб серця**

Глибока згорткова нейронна мережа – це вид штучної нейронної мережі, розроблений для обробки даних з відомою топологією, подібною до сітки, наприклад, зображень, які можна представити як двовимірну сітку пікселів. У мережі даного типу вхідні дані представлені двовимірною сіткою, і кожен шар виробляє вихід, який подається на вхід наступного шару, і так далі.

Нейронні мережі складаються з різних видів шарів. У цьому контексті шар відноситься до послідовних операцій, які мають взаємозв'язки одна з одною або використовуються одна однією. Це допомагає зрозуміти механізми, на яких ґрунтується нейронна мережа та її різні шари.

Наприклад, згортковий шар, який включається в архітектуру мережі, складається зі згортки, шару пакетної нормалізації та випрямленого лінійного блоку. Ця термінологія полегшує розуміння структури нейронної мережі та взаємозв'язків між її шарами. Іноді кожен окрему операцію називають шаром, особливо коли важливий вибір окремих операцій на платформах глибокого навчання.

### **2.3 Застосування згорткового фільтра в нейронній мережі**

Операція двовимірного згортання полягає в використанні дискретного згорткового фільтра, який представляє собою ядро певного розміру, часто квадратного. У багатьох випадках для згортання використовуються ядра розміром  $3 \times 3$ . Згортка обчислюється як сума елементних добутків між цим ядром і фрагментом зображення, який називається сприймаючим полем, для створення одного вихідного пікселя. У результаті отримується зображення, відоме як карта ознак, як показано на рисунку 2.1.

Цей розрахунок виконується для кожного вихідного пікселя, пересуваючи ядро по всьому вхідному зображенню. Кількість пікселів, на які переміщується ядро за одну ітерацію, називається кроком сприймаючого поля.

Значення, які складають ядро, відомі як параметри або ваги, і вони піддаються навчанню, що означає, що вони можуть змінюватися під час процесу навчання.

Під час згортання зображень важливо враховувати відповідність розміру вихідної карти ознак розміру вхідного зображення або карти ознак. Згортка тут відіграє ключову роль, адже вона дозволяє зберігати цю відповідність. Протилежністю до згортки є транспонована згортка, яка представляє собою

зворотну операцію. Вона дозволяє збільшити розмір карт ознак і була використана в запропонованій архітектурі кодера-декодера. Транспонована згортка дозволяє збільшити дискретність на виході.




Рисунок 2.1 – Згортковий фільтр

Важливо відзначити, що згортковий фільтр, який використовує підстановку, призводить до того, що вихід має такий самий розмір, що і вхідні дані.

## 2.4 Функція активації та пакетна нормалізація

Якби в мережі використовувалися тільки лінійні операції, такі як згортки, то всі операції можна було б спростити до однієї єдиної. Однак потрібно внести нелінійність у мережу, оскільки моделі, які близькі до лінійних, оптимізуються легше. Для цього на виході кожної операції згортання використовується нелінійна активаційна функція. Один із прикладів – це функція Rectified Linear Unit (ReLU)  $g(z) = \max(0, z)$ , яка наближена до лінійної функції.

Пакетна нормалізація – це концепція, спрямована на боротьбу з внутрішнім коваріаційним зсувом та покращення швидкості навчання. Внутрішній коваріаційний зсув виникає тоді, коли розподіл вхідних даних для кожного шару змінюється під час навчання на основі зміни параметрів попередніх шарів. Кожен шар навчається на основі вхідних даних від попереднього шару та оновлює свої параметри. Проте це може призвести до зміни вихідних даних попереднього шару, що може ускладнити процес навчання. Щоб вирішити цю проблему, використовують пакетну нормалізацію разом із вказаними методами, що дозволяє поліпшити швидкість та якість навчання мережі.

Внутрішній коваріаційний зсув є проблемою, яку можна розв'язати ретельною ініціалізацією і обмеженням швидкості навчання. Проте при збільшенні глибини мережі ця проблема стає більш вираженою. Використання пачок даних, де кілька зображень обробляються одночасно, а також нормалізація активацій кожної пачки за середнім і дисперсією, дозволяє подолати цей внутрішній коваріаційний зсув. Це дозволяє використовувати великі швидкості навчання і паралельно обробляти декілька зображень, використовуючи можливості графічних процесорів.

Пакетна нормалізація використовується після кожної згортки в згортковому шарі для нормалізації активацій. Важливою концепцією в оптимізації є кроки, якими робляться градієнтні оновлення для функції втрат. Іноді, коли кроки за градієнтом функції втрат вибираються неякісно, це може призвести до проблем зі збіжністю. Один із способів розв'язання цієї проблеми – використання імпульсу, додавання попереднього градієнтного кроку до поточної ітерації. Величина внеску попередньої ітерації в поточну визначається коефіцієнтом імпульсу, який налаштовується перед початком навчання.

Один зі способів подолання перевантаження полягає у використанні вагового розкладання, введенні додаткового критерію для мінімізації під час навчання. Корисним критерієм є прагнення до малих ваг мережі, що можна досягти шляхом мінімізації квадратичної норми  $L_2$  ваг. Це відомо як  $L_2$ -

регуляризація. Результатом є вибір ваг, які знаходяться в компромісі між відповідністю навчальним даним і величиною ваг. Ступінь цього компромісу контролюється коефіцієнтом регуляризації, який налаштовується перед навчанням.

У випадку обробки зображень, операція об'єднання допомагає отримати сумарну статистику навколишніх пікселів. Однією з найпоширеніших операцій об'єднання є максимальне об'єднання, max pooling. Вона виділяє найбільше значення з прямокутної області навколо кожного пікселя і передає його на виході. Операція об'єднання корисна для зменшення роздільної здатності карти ознак. Це допомагає створити більш складне представлення ознак, наприклад, виділити контури за допомогою виявлених країв, не враховуючи точного місцеположення ознак. Це також сприяє невеликій інваріантності до невеликих зсувів вхідного сигналу і може бути корисним для боротьби з перенавчанням.

Операція об'єднання може змінювати свій розмір і довжину фільтра, так само, як і згорткова операція. Серед найпоширеніших параметрів об'єднання можна виділити малий розмір фільтра, наприклад, 2x2 та крок, який дорівнює одиниці. Це робиться для того, щоб уникнути втрати занадто великої кількості інформації щодо місцеположення об'єктів на зображенні.

У сегментації зображень втрата локальної інформації є недоцільною, оскільки місцезнаходження меж об'єктів грає ключову роль. Для отримання більш складних карт ознак використовують техніку, коли карти ознак зберігаються і передаються транспонованому згортковому шару, який виконує відповідний апсемплінг. Наприклад, цей підхід використовується в архітектурі U-net, де карти ознак, отримані внаслідок максимального об'єднання, конкатенуються з вхідними даними транспонованих згорткових шарів, зберігаючи тим самим локальну інформацію. Це часто називають пропуском з'єднань. У Segnet використовується більш обмежена за пам'яттю альтернатива, де зберігаються лише індекси максимального об'єднання в шарі max pooling, і ці індекси передаються транспонованому згортковому шару тієї ж глибини.

1	2	2	1	0
1	1	1	1	1
1	0	2	1	2
2	1	1	1	1
1	1	0	0	1

Рисунок 2.2 – Чисельна ілюстрація максимального об'єднання, де розмір фільтра 3x3 з кроком один

Для виконання сегментації на основі карт ознак необхідно класифікувати кожний піксель на зображенні. Зазвичай це виконується шляхом розміщення спеціального шару для класифікації пікселів в кінці мережі. Цей шар використовує карту ознак, щоб зробити передбачення, до якого класу з найбільшою ймовірністю належить кожен піксель. При цьому також враховуються ваги класів, що вказують на кількість пікселів, які належать до різних класів від загальної кількості пікселів. Зазвичай перед класифікаційним шаром розташований softmax шар. Функція softmax перетворює значення на карті ознак в діапазон від 0 до 1, представляючи ймовірність того, що піксель належить до кожного класу, і забезпечує те, що сума ймовірностей для кожного пікселя дорівнює 1.

На жаль, немає єдиного стандарту для оцінки сегментації зображень, і різні дослідники та завдання сегментації використовують різні метрики. Тому важливо розуміти різницю між цими метриками, а також їхні переваги та недоліки. Для наочності та оцінки ефективності моделі сегментації рекомендується використовувати кілька різних метрик.

Одним із ключових понять є розподіл правильно та неправильно класифікованих пікселів. Правильно класифіковані пікселі вважаються істинно позитивними, тобто тими, які модель вірно визнала як міокард, або істинно негативними, які модель вірно визнала як фон. Неправильно класифіковані пікселі можуть бути помилково позитивними, коли модель помиляється,

вважаючи піксель міокардом, коли це фон, або помилково негативними, коли модель помиляється, вважаючи піксель фоном, коли це міокард. У різних застосуваннях важливість помилкових класифікацій може варіюватися, що вимагає налаштування функцій втрат для більш точного врахування цих аспектів.

Індекс Жаккара, також відомий як коефіцієнт Жаккара, є статистикою, яка використовується для оцінки подібності двох множин, в даному випадку – множини пікселів, класифікованих як міокард. Цей індекс обчислюється як відношення розміру перетину множини до їхнього об'єднання і допомагає визначити, наскільки схожі два набори пікселів.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (2.1)$$

Тут множина  $A$  представляє пікселі, класифіковані мережею як міокард, і множина  $B$  – пікселі міокарда, які є справжніми. Перетин пікселів множин  $A$  і  $B$  відображає істинно позитивні результати, тобто пікселі, які були вірно передбачені моделлю. Об'єднання представляє собою суму істинно позитивних, хибнопозитивних і хибнонегативних результатів, охоплюючи всі можливі класифікації пікселів. Отже, індекс Жаккара може бути інтерпретований наступним чином.

Індекс Жаккара використовується для визначення ступеня подібності між передбаченою сегментацією і справжньою сегментацією. Однак він не завжди повністю відображає ступінь схожості між контурами, що може бути важливим під час візуальної оцінки сегментації людиною.

Показник  $F$ -міра був введений для вимірювання ступеня схожості між двома контурами. Цей показник може бути використаний разом з індексом Жаккара для отримання більш повного розуміння якості сегментації. Він оцінює, наскільки дві межі схожі одна на одну. Оцінка базується на порівнянні точок межі сегментації з межею істинної сегментації. Порівнюючи відстань між цими

точками з допустимим відхиленням, показник допомагає визначити, наскільки точно межа сегментації відтворює справжню межу.

Під час оцінки мереж також розглядається показник точності. Точність обчислюється як відношення кількості правильно класифікованих пікселів міокарда до загальної кількості наявних пікселів міокарда. Цей показник важливий, оскільки саме точність використовується під час навчання для оптимізації моделі.

Опишемо використання нейронні мережі Segnet та Unet. Segnet – це архітектура глибокої нейронної мережі, спеціально розроблена для задач сегментації зображень. Розроблена на основі зображення загорткових нейронних мереж, ця архітектура призначена для визначення піксельних масок об'єктів на зображенні та використовується в сферах комп'ютерного зору та обробки зображень.

Основні характеристики та інновації Segnet включають наступні блоки. Segnet використовує архітектуру з енкодером та декодером, де енкодер відповідає за витягнення високорівневих функцій з вхідного зображення, а декодер відновлює розмірність та деталі сегментованих масок. Ця архітектура сприяє збереженню просторової інформації, що може бути важливим для точної сегментації.

Використання максимального пулінгу та усунення замін. Мережа використовує максимальний пулінг для підвищення стійкості та зменшення розміру карт ознак, а усунення замін для відновлення просторових розмірів та деталей. Також застосовуються контекстні інформаційні блоки для кращого урахування глобального контексту при сегментації об'єктів. Це допомагає забезпечити більш точні результати в умовах складних сцен або з об'єктами різних розмірів.

Для завершення процесу сегментації, Segnet використовує функцію активації softmax для кожного пікселя, щоб визначити ймовірність його належності до конкретного класу.

Segnet була спроектована для високоефективної та точної сегментації зображень і стала популярною в галузі обробки зображень, зокрема в завданнях сегментації сцен та об'єктів на зображеннях.

Загалом можна подати тижий опис архітектури.

Згорткові шари можна представити у такому вигляді:

$$H^{(i)} = \sigma(W^{(i)} * H^{(i-1)} + b^{(i)}), \quad (2.2)$$

де  $H^{(i)}$  – вихідний тензор для шару  $i$ ;

$W^{(i)}$  – ядро (ваги) для шару  $i$ ;

$H^{(i-1)}$  – вихідний тензор для шару  $i-1$ ;

$\sigma$  – функція активації;

$b^{(i)}$  – зсув.

Максимальний пулінг:

$$P^{(i)} = \max_{\text{pool}}(H^{(i)}), \quad (2.3)$$

де  $P^{(i)}$  – вихід після максимального пулінгу.

Значення декодера для усунення замін:

$$U^{(i)} = \text{unpool}(P^{(i)}, H^{(i-1)}), \quad (2.4)$$

де  $U^{(i)}$  – результат усунення замін.

Зворотна згортка або транспонована згортка:

$$D^{(i)} = \sigma(W^{(i)} \cdot U^{(i)} + b^{(i)}), \quad (2.5)$$

де  $D^{(i)}$  – вихід після зворотної згортки.

Контекстні інформаційні блоки можуть бути реалізовані як додаткові згорткові шари або пулінгові шари з додатковими функціями активації.

Функція активації softmax для сегментації:

$$S = \text{softmax}(D^{(i)}), \quad (2.6)$$

де  $S$  – вихідний тензор з ймовірностями належності кожного пікселя до різних класів.

Також використано Unet, що є має архітектуру глибокої нейронної мережі, розроблена для сегментації зображень, особливо в контексті медичних зображень, але також використовується в інших областях. Unet вирізняється своєю ефективністю в роботі з областями, де присутні невеликі кількості даних для навчання та де точність сегментації є важливою.

Основні характеристики та особливості Unet включають такі блоки. Спочатку зображення пропускається через послідовність згорткових шарів та пулінгових шарів, що допомагає витягувати важливі функції та зменшити розмірність. Потім використовується послідовність транспонованих згорткових шарів та конкатенація з відповідними шарами енкодера для відновлення розмірності та деталей. Кожен крок у декодері має на меті відновити роздільно-просторову інформацію, що допомагає уникнути втрати деталей під час процесу сегментації. Додавання інформації з енкодера безпосередньо до відповідних шарів декодера допомагає у врахуванні контексту та поліпшенні точності сегментації. Для кінцевого визначення ймовірностей належності пікселя до класів використовується функція активації softmax.

Unet виявляється особливо ефективним у медичних задачах, таких як сегментація органів на зображеннях з рентгенівських або МРТ-сканів.

Архітектура Unet вдало комбінує глибоке навчання та механізми, спрямовані на збереження контексту та деталей. Це робить її популярною в багатьох областях, особливо там, де потрібна висока точність сегментації при обмежених навчальних даних.

Unet – це архітектура глибокої нейронної мережі, яка була спеціально розроблена для сегментації медичних зображень, але знайшла застосування в інших галузях обробки зображень через її високу ефективність. Архітектура Unet включає в себе енкодер та декодер, з'єднані за допомогою шляхів-з'єднань, що дозволяють відтворювати деталі та структуру об'єктів під час сегментації.

Представимо основні кроки та компоненти Unet.

Згортковий блок.

$$H^{(i)} = \sigma(W^{(i)} * H^{(i-1)} + b^{(i)}), \quad (2.7)$$

де  $\sigma$  – функція активації, така як ReLU;

$H^{(i)}$  – вихідний тензор для  $i$ -го шару;

$W^{(i)}$  – ваги;

$H^{(i-1)}$  – вхідний тензор;

$b^{(i)}$  – зсув.

Максимальний пулінгз меншує розмірність зображення та витягує ключові ознаки:

$$P^{(i)} = \max\_pool(H^{(i)}) \quad (2.8)$$

Декодер усунення замін. Відновлення розмірності після максимального пулінгу:

$$U^{(i)} = \text{unpool}(P^{(i)}, H^{(i-1)}) \quad (2.9)$$

Транспонована згортка повертає розмірність зображення:

$$D^{(i)} = \sigma(W^{(i)} \cdot U^{(i)} + b^{(i)}). \quad (2.10)$$

Функція з'єднання шляхів для- об'єднання виходів енкодера та декодера:

$$M^{(i)} = \text{concatenate}(H^{(i)}, D^{(i)}). \quad (2.11)$$

Вихідний шар:у вигляді функції активації softmax для сегментації. Визначення ймовірностей належності пікселів до класів:

$$S = \text{softmax}(M^{(i)}). \quad (2.12)$$

Архітектура Unet включає енкодер, декодер та механізми з'єднання для покращення точності сегментації об'єктів на зображеннях. Функція активації softmax визначає ймовірності належності пікселів до різних класів, забезпечуючи сегментацію.

## 2.5 Структура глибокої загорткової нейронної мережі

Під час підготовки до проекту було проведено аналіз кількох досліджень, що стосуються використання глибокого навчання для сегментації медичних зображень, зокрема, для сегментації лівого шлуночка. Оскільки існувала значна кількість публікацій на цю тему, було вирішено визначити, наскільки вже наявні реалізації глибокого навчання можуть бути корисними для датасету. З огляду на різноманіття глибоких фреймворків, основна увага була приділена пошуку відповідної мережевої архітектури, яку можна було б легко впровадити та використати для сегментації.

Після ретельного дослідження, було виявлено, що Unet є однією з найбільш ефективних та широко використовуваних архітектур для сегментації медичних зображень. Ця архітектура вже зарекомендувала себе у вирішенні різних завдань сегментації, включаючи сегментацію лівого шлуночка. Вона служила основою, на основі якої розроблялися подальші вдосконалені рішення

та застосування до конкретних завдань, таких як сегментація 3D-зображень, яка є дуже актуальною для визначення лівого шлуночка. Використання U-net як основа дослідження спростило і полегшило процес сегментації групи МРТ-зображень серця, навіть для тих, хто має обмежений досвід у глибокому навчанні.

Спроби використання архітектури U-net для сегментації не дали бажаних результатів, і виникла складність визначення етапів, на яких модель не працює належним чином. В проєкті було вирішено використовувати існуючі підходи. Вони виявилися дуже зручними завдяки своїй простоті в використанні, широкій документації та активній спільноті. Зокрема, в проєкті використовувалася архітектура мережі під назвою Segnet, яка була вже реалізована та добре підтримувалася. Ця архітектура виявилася дієвою для сегментації завдяки своєму вдосконаленню та оптимізації.

У процесі роботи над проєктом було вдосконалено архітектуру Segnet, підлаштовуючи її під конкретні потреби. Також використовувалися інструменти для байєсівської оптимізації гіперпараметрів, що допомогло покращити результати навчання та досягти бажаних показників ефективності.

На початковому етапі проєкту досліджувався альтернативний підхід, який використовував полярне зображення лівого шлуночка. Цей підхід був вивчений та реалізований на ранній стадії проєкту. Він припускав обмеження для моделі, що давало можливість отримати більш фізіологічно коректне відтворення.

Набір даних для проєкту був отриманий з використанням системи магнітно-резонансної томографії. Зображення було зафіксовано для кількох різних досліджень та пацієнтів. Кожен набір даних представляв собою тривимірний об'єм в декількох часових кадрах, що охоплювали один повний серцевий цикл. Експерти з МРТ серця визначили регіони систоли та діастоли на кінцевих зображеннях.

Для створення набору даних було написано плагін для програмного забезпечення сегментації, що дозволило зберігати важливі зображення. З цього

набору обрано зображення серця на кінцевих стадіях систоли та діастоли, які склалися приблизно з 10 зрізів для кожного часового інтервалу.

Верхній зріз та два нижні зрізи були виключені, щоб сформувати набір зрізів середнього шлуночка. Зображення, на яких об'єм міокарда між кінцевими систолічним і кінцевими діастолічними часовими інтервалами відрізнявся більш ніж на декілька відсотків, були виключені. Отже, набір даних було розділено на окремі систолічні та діастолічні набори даних, які отримали назви систолічний і діастолічний. Також створено комбінований набір даних, що включав в себе обидва ці набори, і його названо об'єднаним.

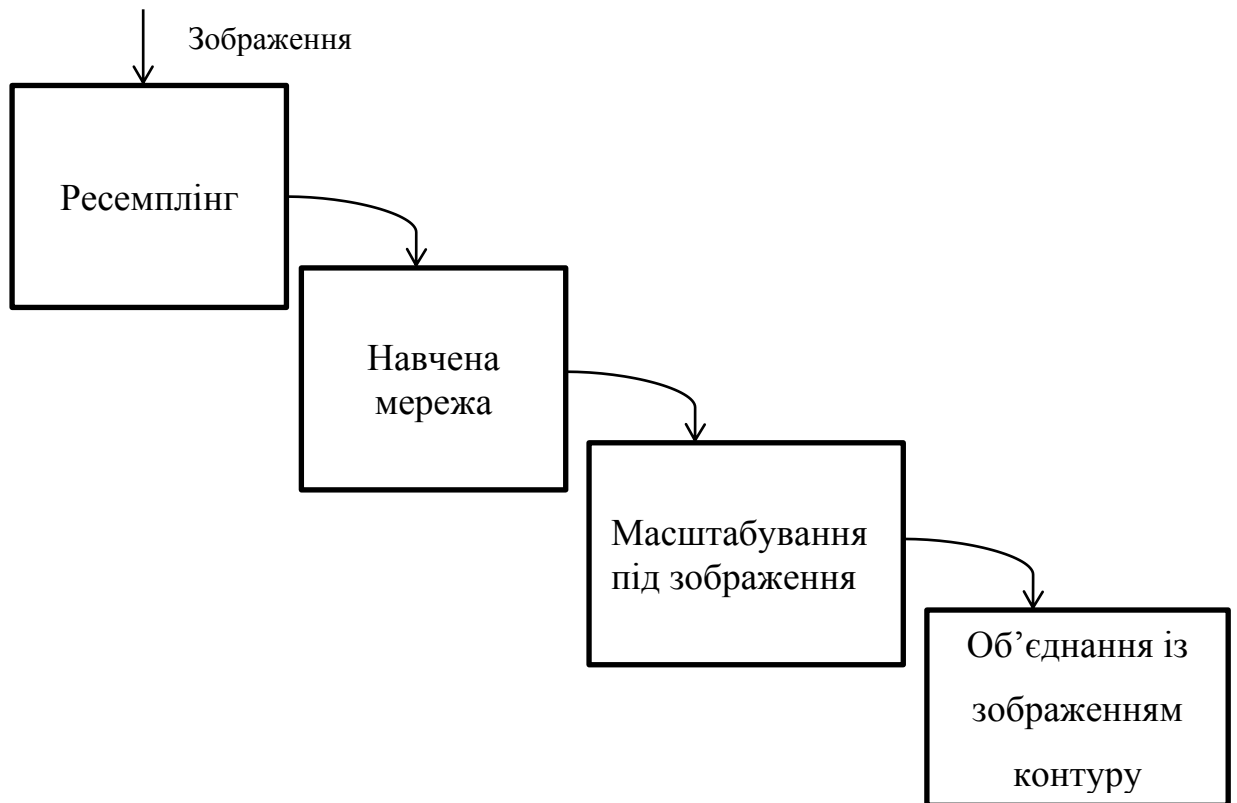


Рисунок 2.3 – Ілюстрація етапів роботи пропонованої системи для сегментації міокарда

Етапи роботи пропонованої системи для сегментації міокарда можна представити у вигляді таких кроків:

Крок 1. Зображення спочатку піддається процедурі ресемплювання для стандартизації просторової роздільної здатності. Розмір пікселя ресемпльованих

зображень установлюється на однаковий рівень, наприклад, 1,5 мм/піксель.

Крок 2. Навчена нейромережа застосовується до ресемпльованих зображень для виділення центрального контуру, що оточує лівий шлуночок. Мережа навчена розпізнавати міокард та фон на основі поданих вхідних зображень.

Крок 3. Після визначення центрального контуру застосовується обрізка зображення розміром 65 x 65 пікселів або іншим, що відповідає 50 мм, навколо центральної точки лівого шлуночка. Зображення редискретизується до розміру 256 x 256 пікселів, забезпечуючи їхню єдність в просторовому діапазоні.

Крок 4. Отримана сегментація, яка містить контур міокарда, об'єднується з вихідним зображенням для створення повноцінного сегментованого зображення міокарда. Контур міокарда проектується на вихідне зображення з вказаним розміром та роздільною здатністю, забезпечуючи точне визначення границь міокарда.

Цей процес гарантує, що результат сегментації відповідає стандартам та може бути ефективно використаний для подальших клінічних досліджень та діагностичних заходів.

У цьому об'єднаному наборі даних використовували ті ж навчальні та тестові дані, що і в окремих систолічних і діастолічних наборах даних. Це було зроблено для можливості порівняти результати роботи моделей, які навчалися на різних часових інтервалах.

В системі, яку пропонується, спершу виконується передпроцесінг, який включає в себе обрізку та повторну вибірку зображення. Цей крок призводить до отримання зображення, готового для подальшої передачі у мережу. Потім це зображення проходить через мережу, результатом чого є отримане попиксельне маркування міокарда та фону. Всі пікселі, які не належать до міокарда, вважаються фоном..

Після цього виконується пост-обробка цього маркування, що призводить до формування контуру сегментованого міокарда та його прив'язки до вихідного

зображення. Ця система призначена для потенційних користувачів, які можуть застосовувати її до зображень для отримання контуру міокарда.

Зображення спочатку піддається процедурі ресемплінгу, а після цього проходить через навчену мережу для виділення центрального контуру, що оточує лівий шлуночок. Отримана сегментація має розмір та роздільну здатність, ідентичні вихідному зображенню, і контури відображаються поверх нього.

На вхід мережі надходять зображення, які можуть відрізнитися за розміром і просторовою роздільною здатністю.

Для розв'язання цієї задачі застосовуються наступні попередні оброблювальні кроки:

1. Зображення ресемплюються до однакової просторової роздільної здатності, а саме 1,5 мм/піксель.

2. Визначається центральна точка зображення.

Ці кроки допомагають уніфікувати вхідні дані та забезпечують належну обробку навколо центру лівого шлуночка.

Для виділення центрального зображення лівого шлуночка здійснюється обрізка зображення розміром 65 x 65 пікселів, що відповідає 50 мм, навколо центральної точки лівого шлуночка.

Після чого зображення редискретизується до розміру 256 x 256 пікселів з просторовою роздільною здатністю близько 0,5 мм/піксель. Цей процес забезпечує наявність зображень із спільним просторовим діапазоном і однаковою роздільною здатністю.

Центральна точка лівого шлуночка визначається наступним чином: обчислюється центр мас для окресленого ендокарда на навчальних і тестових зображеннях. Якщо на зображенні відсутній попередньо визначений міокард, який є об'єктом цілі, то центральна точка виділяється іншими методами.

В результаті обробки мережею формується карту класифікації розміром 256 x 256 пікселів, де кожен піксель визначається як міокард або фон. Контур міокарда виділяється з цієї карти та проектується на вихідне зображення з вказаним розміром та роздільною здатністю.

Послідовність кроків при застосуванні методу.

Крок 1. Збір та підготовка даних.

Об'єднання навчальних та тестових даних. Використання одних і тих самих навчальних та тестових даних для об'єданого набору, забезпечуючи можливість подальшого порівняння результатів моделей.

Крок 2. Передпроцесінг зображення.

Обрізка та повторна вибірка зображення. Виконання передпроцесінгу, включаючи обрізку та повторну вибірку зображень для отримання готового зображення для передачі у мережу.

Крок 3. Передача зображення через нейромережу

Використання навченої мережі. Передача зображення через навчену мережу для отримання попиксельного маркування міокарда та фону.

Крок 4. Пост-обробка результатів сегментації.

Формування контуру та прив'язка до вихідного зображення. Виконання пост-обробки отриманого маркування для формування контуру сегментованого міокарда та його прив'язки до вихідного зображення.

Крок 5. Процедура ресемплінгу та редискретизації

Ресемплювання зображень до однакової роздільної здатності. Застосування ресемплювання для забезпечення однакової просторової роздільної здатності (1,5 мм/піксель).

5.2. Визначення центральної точки зображення.

Визначення центральної точки зображення для подальшої уніфікації вхідних даних.

Крок 6. Адаптація та сегментація шлуночка.

Обрізка та редискретизація зображення до 65 x 65 пікселів. Обрізка зображення навколо центральної точки лівого шлуночка та його редискретизація до розміру 65 x 65 пікселів.

6.2. Редискретизація зображення до 256 x 256 пікселів:

Редискретизація обрізаного зображення до розміру 256 x 256 пікселів для забезпечення спільності просторового діапазону та роздільної здатності.

Крок 7. Визначення центральної точки шлуночка.

7.1. Визначення центру мас для окресленого ендокарда.

Обчислення центру мас для ендокарда на навчальних та тестових зображеннях.

7.2. Автоматичне визначення центральної точки:

Автоматичне визначення центральної точки, якщо міокард не присутній на зображенні.

Крок 8. Формування та проектування сегментації міокарда.

8.1. Формування карти класифікації. Використання мережі для формування карти класифікації розміром 256 x 256 пікселів.

8.2. Проектування контуру міокарда на вихідне зображення.

Проектування контуру сегментованого міокарда на вихідне зображення з вказаним розміром та роздільною здатністю.

Крок 9. Завершення та висновки.

9.1. Аналіз та оцінка результатів:

Проведення аналізу результатів та оцінка ефективності системи.

9.2. Висновки та рекомендації.

Формулювання висновків та рекомендацій для користувачів системи.

## **2.6 Мережева архітектура загорткової мережі**

Застосована архітектура мережі називається Segnet і відзначається своєю повністю згортковою структурою. Вона складається з двох ключових компонентів – кодувальної і декодувальної частин мережі, де кожен кодер відповідає своєму декодеру.

Кодери включають до себе два або три згорткових блоки, які складаються з ядра згортувального шару розміром 3 x 3, за якими слідує шар пакетної нормалізації і шар ReLU. Після кожного згорткового блоку розташовується шар макс-пулінгу з вікном розміром 2 x 2 і кроком 2, що призводить до зменшення

розмірності карти ознак. При цьому кількість каналів ознак подвоюється після кожної знижувальної дискретизації.

Індекси макс-пулінгу, отримані в результаті кожної операції макс-пулінгу, зберігаються та використовуються в декодерах. Декодери є, в певному розумінні, дзеркальними версіями кодерів, але включають в себе де-згорткові шари для підвищення розмірності карти ознак, використовуючи індекси макс-пулінгу, отримані в кодерах.

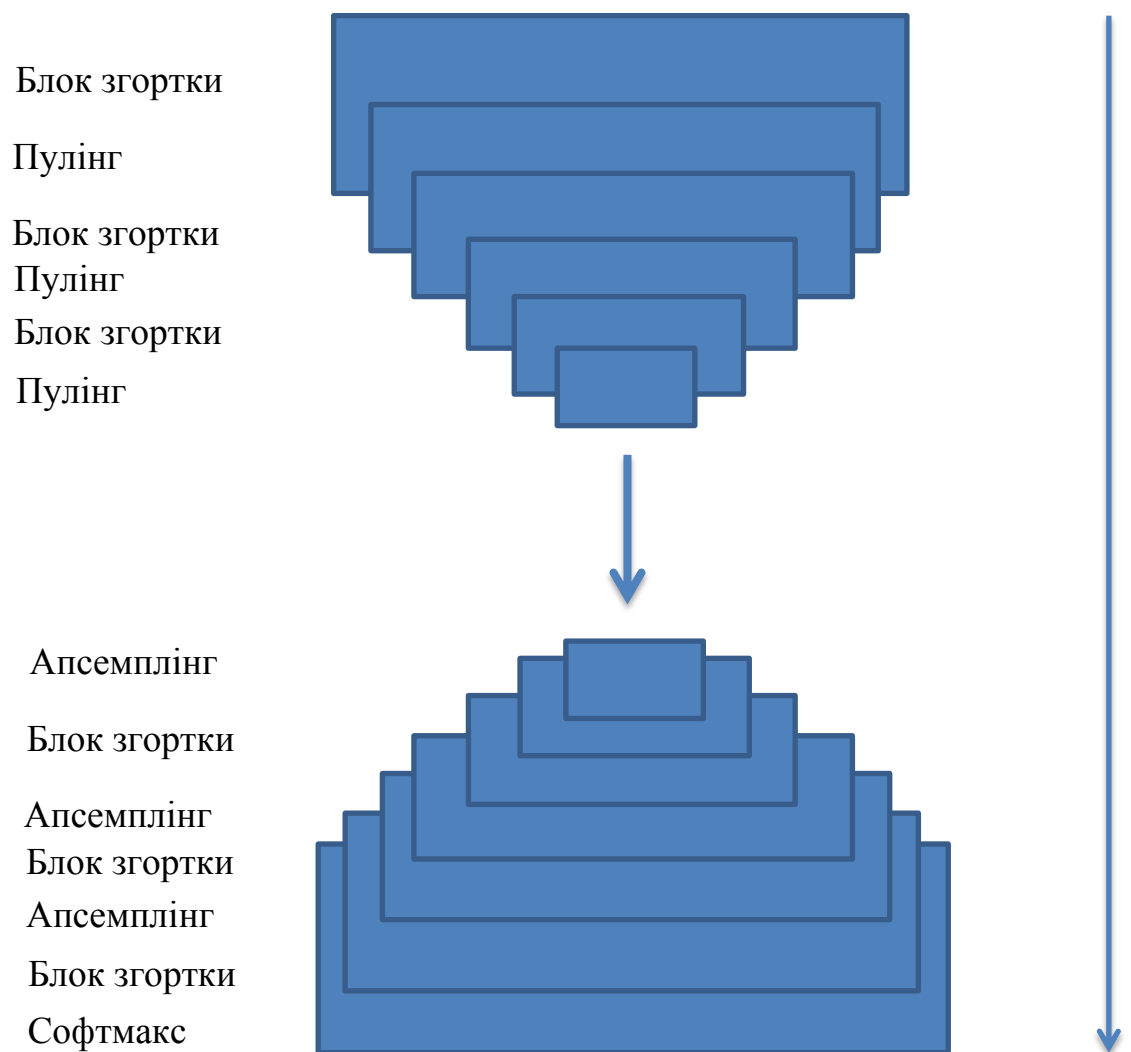


Рисунок 2.4 – Архітектура Segnet

Під час кроків апсемплінгу, де розмір зображення збільшується, і кількість каналів ознак зменшується удвічі, можуть використовуватися транспоновані згортки або методи білінійного апсемплінгу. Ці шари допомагають відновити просторову інформацію, яка може бути втрачена внаслідок зменшення розмірів зображення на попередніх етапах.

На завершення мережі розташований шар Softmax. Шар Softmax використовується для конвертації вихідних значень мережі в ймовірності для кожного класу. Це дозволяє отримати ймовірнісний розподіл для класифікації.

Після шару Softmax слідує шар піксельної класифікації. Цей шар призначений для присвоєння класів кожному пікселю в зображенні. Зазвичай це відбувається шляхом використання загорткових шарів із ядром розміром  $1 \times 1$ , які допомагають зменшити просторовий розмір та призводять до виведення класифікації для кожного пікселя. Цей шар визначає, до якого класу належить кожен піксель на вхідному зображенні, забезпечуючи повністю сегментоване зображення з визначеними класами для кожного пікселя.

Архітектура вдосконаленої мережі є модифікованою версією архітектури Segnet, але відрізняється тим, що кодери завжди складаються лише з двох блоків згортки. Важливою особливістю є те, що кількість каналів ознак залишається постійною, відмінно від Segnet, що робить її менш вимогливою до ресурсів пам'яті.

## **2.7 Схеми навчання загорткової мережі**

Параметри навчання в основному були сталі для всіх експериментів, за винятком деяких нюансів. Базова швидкість навчання становила 0,02, і коефіцієнт імпульсу був встановлений на рівні 0,6. Навчання було розділене на 4 етапи, з кожним етапом по 100 епох, за винятком великого набору даних, де було лише 50 епох. Під час кожного нового етапу швидкість навчання зменшувалася на 20. Коефіцієнт регуляризації дорівнював 0,001. Розмір пакета навчання складав 32, що було обрано так, щоб забезпечити оптимальне використання

ресурсів GPU без втрати пам'яті. Навчальні дані перемішувалися між кожною епохою для кращої репрезентації навчального набору.

Дані були піддані доповненню за допомогою випадкових зсувів у всіх напрямках, в межах від 10 пікселів до 10 пікселів. При цьому було уникнуто доповнень, які могли б виглядати фізіологічно неправдоподібними, і це питання залишено для подальших досліджень.

Процес реалізації та навчання мережі виконувався за допомогою мови програмування Python та використанням інструментарію для нейронних мереж. Навчання проводилося на графічному процесорі з 4 Гб вбудованої пам'яті.

## **Висновки до розділу 2**

У розділі проведено вдосконалення архітектури Segnet. Це вдосконалення було досягнуте шляхом налаштування архітектурних елементів під конкретні потреби проекту. Крім того, використовувалися підходи для оптимізації гіперпараметрів, що сприяло покращенню результатів навчання та досягненню бажаних показників ефективності.

На початковому етапі дослідження був розглянутий альтернативний підхід, який використовував полярне зображення лівого шлуночка. Цей підхід був ретельно вивчений та реалізований на ранній стадії проекту. Він передбачав обмеження для моделі, що дозволяло отримати більш фізіологічно точне відтворення.

Це дозволило покращити ефективність методу сегментації міокарда за рахунок стандартизації та уніфікації вхідних даних. Передпроцесінг, такий як ресемплювання та редискретизація, сприяє підвищенню надійності результатів навчання мережі, забезпечуючи оптимальні умови для аналізу. Централізоване визначення точки лівого шлуночка спрощує обробку та забезпечує консистентність у вибірці. Загальний підхід покращує точність сегментації, зробивши його ефективним інструментом для діагностики серцево-судинних захворювань та розвитку методів лікування.

## **Розділ 3 Адаптація моделі та застосування до множини даних**

### **3.1 Набори даних зображень серця на основі магніто-резонансних досліджень**

Вивчено набори даних, що містять зображення серця, отримані під час виконання завдань з сегментації лівого шлуночка на таких платформах, як Cardiac MR Left Ventricle Segmentation Challenge-Sunnybrook (LVSC), Automated Cardiac Diagnosis Challenge (ACDC), та Ohio State Cardiac MRI Raw Data (OCMR). LVSC включає 45 учасників, середній вік 61 рік, віковий діапазон від 23 до 88 років, які брали участь у клінічних дослідженнях в Sunnybrook Health Sciences Centre. Серед них були як здорові добровольці 9, так і пацієнти з гіпертрофією 12 або серцевою недостатністю, включаючи інфаркт 12 та без нього 12.

Для отримання двовимірних короткоперіодичних кінетичних зображень всього серця використовувалася послідовність SSFP на сканері Signa, GE Healthcare. Параметри сканування включали розмір вокселя в діапазоні 1,25-1,56 мм<sup>2</sup>, товщину зрізу 8-10 мм, міжзрізовий проміжок 8 мм, 6-12 зрізів та 20 фаз на серцевий цикл.

Для кожного учасника були виконані ручні сегментації міокарда та кровоносної порожнини лівого шлуночка на зображеннях в кінці діастоли кардіологом, в той час як лише порожнина лівого шлуночка була сегментована вручну в кінці систоли. Отже, це дослідження використовувало лише дані МРТ у фазі кінцевої діастоли, які мають 45 зображень.

Набір даних ACDC містить інформацію про 100 учасників, отриманих в Університетській лікарні Діжона, Франція. Набір охоплює п'ять чітко визначених категорій патологій по 20 осіб у кожній, серцева недостатність з інфарктом міокарда, дилатаційна кардіоміопатія, гіпертрофічна кардіоміопатія, аномалія правого шлуночка та здорові суб'єкти. Двовимірні короткофокусні зображення лівого шлуночка, охоплюючи його весь об'єм, були отримані на 1,5T

або 3,0T сканерах Siemens Aera і Siemens Trio, Siemens Medical Solutions, за допомогою SSFP-послідовності, розмір вокселя 1,34-1,68 мм<sup>2</sup>, товщина зрізу 5-10 мм, міжзрізовий проміжок 5 мм, 28-40 фаз на серцевий цикл). Варіабельність якості зображення включала шум, артефакти руху, смуги, низькочастотні флуктуації інтенсивності МРТ-зображень, низькочастотні флуктуації низькочастотної інтенсивності МРТ та різне поле зору.

Ручна сегментація проводилася на кінематографічних зображеннях у фазах як кінцевої діастолі, так і кінцевої систолі, після чого результати були двічі перевірені двома незалежними експертами для досягнення консенсусу.

Набір даних від Sunnybrook Cardiac MR Left Ventricle Segmentation Challenge включає зображення серця з 45 послідовностей, що охоплюють серцеву недостатність з ішемією, серцеву недостатність без ішемії, гіпертрофічну кардіоміопатію, а також здорових осіб. Цей набір даних є першим у своєму роді для автоматизованої сегментації міокарда на основі короткофокусної МРТ. Для кожного пацієнта надаються ручні контури лівого ендокарда та координати епікарда для кінцево-діастолічного та кінцево-систолічного зрізів як базова сегментація.

Контурні дані зберігаються у текстових файлах, які включають в себе x- та y-координати точок контуру. Загалом було виділено 803 області інтересу, а розміри зображень були змінені до 368 на 368 за допомогою білінійної інтерполяції.

Важливо відзначити, що ручна сегментація набору даних LVSC не завжди узгоджується між суб'єктами, і в ручних анотаціях присутній значний шум. Крім того, цей набір даних містить зображення з сегментацією порожнини і міокарда лише у кінцевій діастолічній фазі.

Набір даних OCMR представлений у форматі HDF5, і дані відповідають стандарту ISMRMRD. Всього нараховується 265 файлів даних, кожен з яких є окремим сканом. З них 53 скани, 81 зріз мають стандартну дискретизацію в напрямку фазового кодування, тоді як інші 212 сканів, 842 зрізи мають перспективну знижену дискретизацію. Ці дані були отримані на трьох сканерах

Siemens MAGNETOM: Prisma (3 T), Avanto (1,5 T) і Sola (1,5 T). Кожному скану присвоєно вісім атрибутів, що дають можливість завантажити лише підмножину набору даних OCMR.

Набір даних ACDC було використано для переднього навчання згорткової нейронної мережі, що надало можливість дослідити стійкість до шуму анотацій та узагальнюваність від кінцевої діастолічної фази до кінцевої систолічної фази для алгоритму сегментації на основі глибокого навчання. Набір даних ACDC був розділений випадковим чином на 10 і 90 суб'єктів для точної настройки і тестування відповідно. Всі використані в цьому дослідженні дані були анонімізовані, і отримання дозволу на використання цих публічних наборів даних не було необхідним відповідно до етичних норм.

### **3.2 Формат даних зображень серця**

Сучасні медичні пристрої для візуалізації в основному використовують формат зображень DICOM для зберігання даних. Стандарт цифрової візуалізації та комунікації в медицині Digital Imaging and Communications in Medicine DICOM розвивався зі стандартів, встановлених Американським коледжем радіології та Національною асоціацією виробників електротехніки. DICOM є складним і всебічним стандартом, охоплюючи як передачу, так і стиснення даних, і продовжує еволюціонувати.

Напочатку стандарт налічував 4902 друковані сторінки, але не включав докладну інформацію про аспекти, такі як стиснення зображень. У додатку до цього видання описано 37 різних форм синтаксису передачі, що охоплюють схеми кодування даних зображень. Крім того, розділ містить згадки про 123 різних методи передачі і передача даних у форматі DICOM часто включає файли DICOM з відсканованими записами пацієнта, аудіофайли та інші вбудовані дані.

При акценті на радіологічних методах, для обробки наборів даних DICOM у програмному забезпеченні для нейровізуалізації необхідно розглядати файли DICOM як збереження інформації з різних методів, враховуючи

різноманітність вмісту, такого як відскановані дані пацієнта, аудіофайли та інші форми вбудованих даних.

Стандарт DICOM описує формат на основі тегів, де кожен об'єкт у файлі інкапсульований в тег, що визначає призначення і розмір цього фрагмента даних. Зазвичай, попередні об'єкти утримують інформацію про учасника, пристрій, послідовність зйомки та характеристики зображення, наприклад, розміри зображення, тоді як останній об'єкт кодує самі дані зображення. Кожен об'єкт містить тег, необов'язкове представлення значення, довжину та саме значення об'єкта. Тег - це двоцифровий код, що визначає значення елемента. Означення елемента залежить від словника DICOM. Стандарт DICOM визначає словник для великої кількості змінних, які називаються публічними тегами.

Крім того, стандарт дозволяє виробникам визначати власні теги, відомі як приватні теги. Перший елемент двоцифрового коду публічних тегів завжди парний, у той час як для приватних тегів, визначених виробником, він непарний. Це забезпечує відсутність конфліктів між приватними та публічними тегами, але різні виробники можуть використовувати один і той самий блок приватних тегів для різних цілей.

Додатковий компонент об'єкта представляє собою двосимвольний код, який визначає тип даних, що містяться в об'єкті. "US" вказує на беззнакове коротке ціле число, "DS" – десятковий рядок і так далі. Присутність або відсутність поля VR у файлі залежить від синтаксису передачі, який може бути неявним або явним. У випадку явного синтаксису передачі VR кодується у файлі, тоді як для неявного синтаксису VR потрібно визначити з тегу, використовуючи словник.

Для неявно представленого синтаксису VR може бути недоступним або дуже важким для відстеження для приватних тегів, що ускладнює інтерпретацію даних. Хоча більшість сучасних DICOM-файлів використовують явний синтаксис передачі VR, стандарт DICOM за замовчуванням передбачає неявний синтаксис передачі VR. Ще однією ускладненістю є те, чи використовується явний синтаксис передачі велико- чи мало-кінцевою формою.

Length вказує кількість байт, які містять збережене значення, тоді як останній компонент кодує саме це значення. Ця довжина надає інформацію, необхідну для визначення місця початку наступного об'єкта у файлі.

В DICOM-файлі може бути багато об'єктів (зазвичай близько сотні, але для багатокадрового ICOM їх може бути значно більше). Також існують важливі об'єкти, які часто використовуються для перетворення DICOM в NIfTI.

Унікальний ідентифікатор UID синтаксису передачі кодує важливу інформацію про те, як розшифровувати решту DICOM-файлу. Він визначає синтаксис передачі та інші деталі, такі як методи стиснення для даних зображення.

Інші параметри, такі як рядки, стовпці та розмірність піксельних даних, визначають формат зображення. Зазвичай, кожен файл DICOM включає в себе інформацію про один 2D-зріз, хоча існують винятки з цього правила. Позиція зображення та орієнтація в координатах пацієнта визначають розташування та орієнтацію зрізу в просторі сканера. Відстань між пікселями та товщина зрізу або відстань між зрізами визначають розмір вокселя у тривимірному просторі.

Характеристики, такі як серії, номери екземплярів та інші параметри, використовуються для класифікації DICOM-файлів. Ці об'єкти важливі для сортування та систематизації зображень. Проте, іноді вони можуть бути відсутні, вимагаючи використання евристичних підходів для визначення того, які зрізи слід об'єднати в один 3D-об'єм.

У порівнянні з DICOM, формат NIfTI стає дуже зручним для випадків де потрібна простота. Він забезпечує однорідну основу для зберігання, передачі та відображення медичних даних, спрощуючи процес. Однак, враховуючи постійний розвиток аналітичних методів та обробки даних, використання DICOM може вимагати значних зусиль та витрат. У зв'язку з цим, віддано перевагу менш складним форматам зображень, які дозволяють швидше досягти результатів. Такі прості формати, хоча і містять обмежений набір метаданих, виявляються більш практичними в дослідницькому середовищі.

Формат NIfTI визначається його простотою та мінімалістичністю. Зокрема, в нейровізуалізаційних дослідженнях NIfTI здобув широке визнання, дозволяючи науковцям комбінувати інструменти обробки та аналізу зображень, розроблені різними командами.

Відповідно розроблений як розширення формату файлів `analyze-7.5`, формат NIfTI визначає 348 байт заголовку та нестиснутим даним зображення. Важливо відзначити, що спільнота розробила бібліотеки для читання і запису файлів NIfTI, спрощуючи процес підтримки цього формату та дозволяючи уникнути занової реалізації, що займає багато часу.

Формат NIfTI може зберігати дані заголовка та зображення в окремих файлах або в одному файлі з розширенням `.nii`. Його особливістю є можливість визначення до 7 вимірів для зображення, включаючи просторові виміри, час та інші аспекти, такі як напрямок градієнта дифузії. Розташування просторових вимірів не обов'язково повинно відповідати лівому-правому, задньому-передньому та нижньому-верхньому порядку, хоча для аксіально орієнтованих знімків це є стандартним.

Однією з ключових переваг формату NIfTI порівняно з його попередником, форматом `analyze`, є розширена можливість зберігати інформацію про просторову орієнтацію. Це сприяє зменшенню ймовірності виникнення ліво-правосторонніх помилок у програмному забезпеченні, яке підтримує NIfTI. Зокрема, зображення в форматі NIfTI можуть містити два незалежних просторових перетворення для відображення даних зображення в різні системи відліку.

Одне з цих перетворень, позначене як `"sform"`, дозволяє кодувати повне 12-параметричне афінне перетворення. Друге, відоме як `"qform"`, дозволяє лише 9-параметричне відображення. Останнє обмежене перетворення включає кодування трансляцій, поворотів через кватерніонне представлення та ізотропного масштабування. Хоча це відмінно підходить для відображення вокселів більшості зображень МРТ у деяку евклідову систему координат, 9-

параметричне перетворення недостатньо для кодування зсувів, які часто необхідні для коректного врахування нахилу сканерів.

Включення різних просторових перетворень у заголовок NIfTI може призвести до деякої непорозуміння. У випадку наявності як `sform`, так і `qform` представлень, деякі програми, такі як MRICron і SPM, надають перевагу `sform`, в той час як інші, наприклад, ті, які ґрунтуються на засобах для сегментації та реєстрації за замовчуванням використовують `qform`. В результаті одне й те саме зображення може виглядати по-різному у різних програмах перегляду, і вихідні дані для реєстрації можуть відрізнитися між різними інструментами.

Хоча простота формату NIfTI є його головною перевагою, вона водночас обмежує обсяг інформації, яку можна зберігати в заголовку. Це обмеження може спричинити плутанину при роботі з певними послідовностями, зокрема, дифузійними зображеннями та багатосмуговими послідовностями. Хоча формат NIfTI дозволяє розширенням кодувати таку інформацію, для консенсусу серед спільноти щодо їхнього узгодженого використання потрібен додатковий зусилля. З цієї причини багато пакетів, наприклад, SPM, можуть ігнорувати будь-які розширення.

Розглянемо деякі параметри у заголовку NIfTI, які використаємо в практиці.

Поле "dim" містить інформацію про розмірність даних зображення. Перше число вказує на загальну кількість вимірів, при цьому наступні чотири числа визначають розмірність кожного виміру. Зазвичай перші три виміри відображають простір, а четвертий – час але цю домовленість можна застосовувати з обережністю.

Інформація з `qform` та `sform` вказує на два методи кодування афінних відображень, про які було згадано раніше. Це дозволяє представити орієнтацію зображення без нахилу, що відображається нулями для трьох кватерніонних параметрів і значеннями `pixdim` для діагоналі афінного перетворення. У випадку невеликого нахилу від головних осей ці значення можуть бути трохи меншими за 3, і нулі можуть замінитися числами з невеликою абсолютною величиною.

Три параметри `qoffset` представляють зсув у трьох вимірах простору і збігаються з останнім стовпчиком матриці перетворення `sform`, якщо `sform` та `qform` використовуються для кодування однієї і тієї ж системи координат.

Важливо враховувати одну з ключових особливостей цих параметрів. При осьовій зйомці параметри перетворення можуть значно відрізнитися навіть для одного і того ж набору даних. Зазвичай три кватерніони приймають форму позитивну або негативну, а `grow_x` може мати значення протилежні значення. Це свідчить про те, що дані зображення зберігаються у тимчасовому сховищі. Це означає, що однаковий набір даних може бути організований різним чином і з використанням різних параметрів перетворення. При їхньому об'єднанні у програмі для перегляду зображень вони будуть відображатися як ідентичні.

Проте, при використанні аналізу даних зображень NIfTI слід пам'ятати про цю варіацію і за потреби використовувати відповідні перетворення для відображення зображень у правильному положенні. Якщо орієнтація зрізу відрізняється від осьової, можна відновити зображення так, ніби вони були отримані в осьовому зрізі. Це не порушить формат NIfTI і може уникнути непорозумінь у деяких інструментах аналізу та візуалізації. Проте існують інші важливі обставини, які можуть вплинути на це рішення.

Одне з основних побоювань виникає внаслідок того, що більшість інструментів аналізу вважають третій вимір як вимір зрізу, і в інших випадках вони можуть некоректно виконати корекцію часового виміру. Якщо перше число афінного перетворення має велике абсолютне значення, це свідчить про те, що третій вимір даних зображення знаходиться вздовж осі зліва-направо, і, відповідно, четверті числа в `dim` і `pixdim` відносяться до цієї осі. Без проведення реорганізації даних зображення це може вказувати на отримання сагітального зрізу.

Для перетворення DICOM в NIfTI перший крок – це сортування файлів за різні серії. Серія DICOM включає набір DICOM-зображень, які були створені разом на одному обладнанні під час однієї операції. Найнадійніший спосіб сортування серій - за ідентифікатором DICOM-об'єкта Series Instance UID, хоча

це можна також виконати, об'єднавши об'єкти patient name – ім'я пацієнта), study ID - ідентифікатор дослідження і series number – номер серії.

Такий підхід дозволяє систематизувати дані для подальшого перетворення та забезпечення правильного інтерпретування розмірності та орієнтації зображення в NIfTI.

В межах кожної серії важливо відсортувати зображення за різними томами, якщо це можливо, що зазвичай визначається номером екземпляра. Це може вимагати використання різних об'єктів, таких як Номер зйомки, Номер ехограми, Позиція пацієнта в зображенні, Тип зображення та інші, для надійного сортування зображень у серії. Такий підхід може призвести до складання зображень з декількома вимірами.

Параметри просторового перетворення мають велике значення в заголовку NIfTI. Матриця перетворення математично використовується для проектування індексів вокселів на розташування в системі координат пацієнта для DICOM. Для побудови матриці перетворення зазвичай потрібні об'єкти DICOM, які надають відомості про просторове розташування зображення.

Інструменти для перетворення DICOM в NIfTI відмінно працюватимуть при обробці типових даних нейровізуалізації. Тут типові відносяться до зображень, аналогічних тим, які спостерігаються у команд, що розробляли інструменти для конвертації. Наприклад, більшість цих інструментів, таких як dcm2nii та SPM виникли в лабораторіях, які використовують МРТ-системи Siemens. Таким чином, стандартною конвертацією може бути перетворення тисяч DICOM-файлів для коректного аналізу та організації анатомічного скану, у вигляді одного 3D NIfTI-файлу, а серії МРТ-зображень - у вигляді другого NIfTI-зображення.

Однак нестандартні варіанти можуть включати різні модальності, такі як карти поля, дифузія, КТ і так далі, або зберігання на DICOM-сервері, який стискає дані зображення. Також різні постачальники, наприклад, Philips, можуть впливати на конвертацію. Описімо, як відмінності в постачальнику, методах

передачі та кодуванні можуть впливати на процес конвертації. Різні інструменти спеціально розроблені для вирішення різних аспектів цих ситуацій.

Заголовок формату NIfTI успадковує свою структуру, розмір якої становить 348 байтів, від формату даних ANALYZE. Останні чотири байти у заголовку NIfTI відповідають полю "magic" і вказують, чи містяться заголовок і зображення в одному файлі чи в окремих файлах. Останній варіант ідентичний структурі даних формату ANALYZE.

У форматі даних NIfTI було додано ще чотири байти для врахування розширень у заголовку. За замовчуванням ці чотири байти мають значення нуля.

Інформація про зображення розпочинається з позиції байта, визначеної параметром voxoffset. У випадку єдиного NIfTI, це, за замовчуванням, становить перші 352 байти. Розширення заголовків збільшує їхній розмір і розташовується перед інформацією про зображення, що призводить до відповідного збільшення значення зсуву даних зображення для окремих NIfTI-зображень.

Формати NIfTI та ANALYZE розділені, містячи пари файлів, де інформація про заголовок та зображення розташовані окремо, і не стикаються з описаними раніше проблемами. У цьому випадку vox\_offset дорівнює 0. Функція зображення була перевизначена так, що її поведінка є непередбачуваною при роботі з об'єктами медичних зображень nifti, яка створює тривимірний масив MNI мозку, із NIfTI осями за замовчуванням, і відображає його на сітці зображень. Функція відображення для об'єктів медичних зображень це спроба збалансувати мінімальне втручання користувача з достатньою можливістю налаштувати відображення за потреби. Окремі зрізи можна переглядати за допомогою опції plot.type = single в поєднанні з опцією вказування глибини зрізу.

### **3.3 Сегментація зображень магніто-резонансного аналізу**

Під час обробки МРТ-зображень серця медичні фахівці акцентують увагу на вимірах клінічних параметрів, таких як об'єм шлуночків, маса міокарда і

фракція викиду. Початковий етап включає в себе виділення ключових органів та структур на зображенні серця. Зазвичай завданням радіолога є ручне намалювання контурів, що охоплюють ці важливі структури. Проте цей процес вимагає близько до півгодини на об'єкт і є тривалим, монотонним і може призводити до суб'єктивних помилок.

У зв'язку з цим вивчається можливість використання автоматизованої сегментації та аналізу МРТ-зображень для швидкого виділення меж основних субчастинок серця. Початковий фокус спрямований на лівий шлуночок через його варіабельну форму та складність сегментації порівняно з іншими частинками серця. Також відзначається, що апікальні зрізи можуть бути складні для сегментації через меншу та менше передбачувану інформацію в кінці лівого шлуночка.

Обробка медичних зображень на низькорівневому рівні використовує методи піксельної обробки та математичне моделювання для створення систем аналізу на основі правил. Один із простих та популярних методів – це порогова обробка, яку можна застосовувати глобально з використанням гістограми сірого рівня для всього зображення або локально з використанням, наприклад, матриці кокурентності інформації.

У простому випадку, коли зображення має дві області з різним рівнем яскравості, його гістограма матиме два піки, розділені долиною. Дно цієї долини використовується як поріг для виділення фону та об'єкта. Однак у реальних умовах вибір правильного порога стає складним завданням.

Більш складні варіанти цього методу включають в себе вибір кількох порогів для досягнення неоднорідної сегментації зображень, таких як адаптивна порогова обробка або мультипорогова сегментація.

Останній метод, ширше визначений, узагальнює інші популярні піксельні методи. Наприклад, ітеративний підхід, відомий як релаксація, дозволяє паралельно класифікувати кожен піксель. На кожній ітерації рішення, ухвалені для сусідніх точок, об'єднуються для прийняття рішення наступної ітерації. Ще

одним прикладом є виявлення країв, де край на півтоновому зображенні визначається як набір точок з різкою зміною значень інтенсивності.

Низькорівневі характеристики, такі як краї, можуть бути виявлені лише на основі локальної інформації без високорівневого аналізу зображення. Це призводить до паралельних рішень, які визначають, чи є точка краєм чи ні, з використанням декількох сусідніх точок. У літературі існує багато методів з різноманітними рівнями розпаралелювання.

Однак ці піксельні методи виявилися неефективними в виявленні меж об'єктів у текстурі серця через широкий діапазон інтенсивності та відсутність перекриттів на краях. Проблему було вирішено введенням статистичних і фізичних припущень, отриманих зі структури серця.

Для розробки статистичних моделей стали популярними методи, які використовують набір навчальних даних у якості зразків або шаблонів. Замість того, щоб використовувати лише значення інтенсивності для формування контурів на зображеннях серця, статистичні методи враховують додаткові ознаки щодо форми, руху, текстури та варіацій інтенсивності. Це дозволяє обмежити процес виділення, оскільки контури серця залишаються стабільними в просторовому та часовому вимірах та для різних пацієнтів.

В загальному випадку усі людські серця можна моделювати як еліпсоїдні об'єкти, що рухаються всередині та ззовні. З цього приводу намагалися розробити кардіологічні умови та включити їх у різноманітні методи сегментації як додаткові обмеження для подолання обмежень низькорівневих піксельних методів.

Класифікація статистичних методів може здійснюватися в залежності від способу визначення та використання пріорів, які дозволяють маніпулювати раніше сегментованими контурами для виявлення нових. Активні моделі будують попередню оцінку форми, використовуючи дані, що були вручну сегментовані. Модель форми відображає типову структуру набору анатомічних об'єктів, тому вона інваріантна до застосовуваних до них перетворень. Процес

сегментації розпочинається з вирівнювання всіх навчальних даних за заданими координатами за допомогою методів жорсткої реєстрації.

У випадку нерівної кількості кадрів використовується інтерполяція в часі для приведення їх до однакового вигляду. За отриманим набором координат модель фігури можна визначити як статистичну карту цих точок у вигляді середнього значення та коваріації.

Процес сегментації анатомічних об'єктів за допомогою моделі форми, яка є інваріантною до застосовуваних до них перетворень, може бути розписаний на кілька кроків. Розглянемо цей процес поетапно:

Крок 1. Підготовка навчальних даних. Збір навчальних даних, які містять зображення анатомічних об'єктів, та відповідні координати цих об'єктів для тренування моделі форми.

Крок 2. Всі навчальні дані вирівнюються за заданими координатами за допомогою методів жорсткої реєстрації. Це дозволяє узгоджувати позиції об'єктів у всьому навчальному наборі.

Крок 3. Перевірка однорідності кількості кадрів. Перевірка чи всі зображення мають однакову кількість кадрів. Якщо ні, то переходимо до наступного кроку. Виконання інтерполяції в часі для зображень з неоднорідною кількістю кадрів. Це дозволяє привести їх до однакового вигляду у часі, що полегшує подальший аналіз.

Крок 4. Визначення моделі форми. Отримання набору координат об'єктів на вирівняних та інтерпольованих зображеннях. Модель форми визначає фігуру як статистичну карту координат, яку можна представити у вигляді середнього і коваріації.

Крок 5. Визначення областей інтересу. Використання отриманої моделі форми для сегментації областей інтересу на нових зображеннях. Забезпечення інваріантності до застосовуваних перетворень об'єктів шляхом використання моделі форми, яка враховує їх структуру.

Отримана модель форми дозволяє ефективно визначати та відокремлювати анатомічні об'єкти на нових зображеннях, забезпечуючи інваріантність до різних перетворень.

Позначимо множину координат точок, яку отримали після вирівнювання і, при необхідності, інтерполяції в часі, як  $(X = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\})$ , де  $(n)$  – кількість точок.

Визначення середнього значення (середні координати).

Середнє значення координат  $(\bar{x})$  може бути обчислене наступним чином:

$$x = \frac{1}{n} \sum_{i=1}^n (x_i, y_i). \quad (3.1)$$

Коваріаційна матриця.

Коваріаційна матриця  $S$  для визначення форми фігури може бути обчислена наступним чином:

$$S = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{x})(X_i - \bar{x})^T, \quad (3.2)$$

де  $X_i$  – вектор координат точки  $i$ ;

$X_i - \bar{x}$  – вектор, який представляє відхилення точки  $i$  від середнього значення;

$(X_i - \bar{x})^T$  – транспонований вектор.

Коваріаційна матриця є важливим показником, який вказує на розмір і орієнтацію форми фігури відносно її центру.

Отже, формула для статистичної картографії фігури може виглядати наступним чином:

$$F = (\bar{x}, S) \quad (3.3)$$

Така модель може використовуватися для подальшої сегментації або аналізу форми фігури на основі статистичних властивостей.

З отриманою статистичною картою ( $F = (\bar{x}, S)$ ), можна використовувати гаусіанську апроксимацію для отримання більш гладкої репрезентації фігури. Один з підходів - це використання многовимірного гаусіана, параметри якого визначаються середніми значеннями та коваріаційною матрицею:

$$P(x, y) = \frac{1}{2\pi\sqrt{\det(S)}} \exp\left(-\frac{1}{2}(X - \bar{x})^T S^{-1}(X - \bar{x})\right), \quad (3.4)$$

де  $X = (x, y)$ ,  $\bar{x}$  – середнє значення;

$S$  – коваріаційна матриця.

З гаусіанської апроксимації можна визначити контур фігури. Це може бути зроблено, наприклад, шляхом вибору рівня ймовірності або інших методів визначення контуру.

Такий підхід дозволяє моделювати форму фігури та використовувати статистичні характеристики для подальшого аналізу чи сегментації. Важливо розуміти, що в даному контексті ми використовуємо статистичні методи для опису просторового розподілу точок у вигляді статистичної картографії та гаусіанської апроксимації, що може бути корисним у великому спектрі задач від аналізу зображень до медичної діагностики.

Для отримання ще більш компактної апроксимації фігури використано, наприклад, еліпсоїд, якщо розглядається двовимірний простір. Еліпсоїд визначається параметрами, такими як центр  $\bar{x}$ , напрямки осей, визначаються власними векторами коваріаційної матриці  $S$  та довжина осей, визначаються власними значеннями коваріаційної матриці.

Загальна форма рівняння еліпсоїда:

$$(x - \bar{x})^T S^{-1}(x - \bar{x}) = 1, \quad (3.5)$$

де  $S^{-1}$  – обернена коваріаційна матриця.

Отриману модель фігури можна використовувати у процесі сегментації. Наприклад, можна встановити поріг ймовірності для відсічення непотрібних областей та виділення областей, що відповідають фігурі.

Цей підхід до сегментації може бути особливо корисним у випадках, коли точна форма об'єкта на зображенні не є простою геометричною фігурою та може варіюватися. Загальною метою цього процесу є створення ефективної та точної моделі для репрезентації та аналізу форми об'єктів на зображеннях з метою полегшення подальших обчислень та аналізу.

У випадках, де важлива динаміка об'єкта з часом, можна розглядати моделювання не лише статичної форми, але й зміни цієї форми в часі. Введення параметрів, що відповідають за рух чи зміни форми, може бути корисним для аналізу об'єктів у відео чи динамічних зображеннях.

Отримані таким чином моделі можуть слугувати основою для навчання систем штучного інтелекту, які здатні автоматично сегментувати об'єкти на зображеннях. Можливість автоматичного визначення параметрів та форми об'єктів є ключовою для розвитку систем аналізу зображень.

Оптимізація обчислень та алгоритмів є важливою для швидкого та ефективного визначення параметрів моделі. Використання таких статистичних моделей дозволяє покращити продуктивність та точність сегментації у порівнянні з класичними методами, особливо при великій кількості даних.

Для перевірки точності та універсальності отриманих моделей важливо провести їхню валідацію на тестових наборах даних. Зміни у параметрах та алгоритмах можуть виникнути залежно від конкретного завдання, і вони повинні бути підтверджені експериментами.

У разі застосування системи в реальному часі, критично важливо оптимізувати алгоритми та обчислення для забезпечення ефективної та швидкої роботи системи, не компромітуючи якість сегментації.

Схожим чином, здебільшого використовується підхід, що поєднує статистичні методи та технології машинного навчання. Це дозволяє створювати точні та продуктивні моделі сегментації об'єктів на зображеннях, які можуть знайти застосування в різних областях.

### **Висновки до розділу 3**

У розділі було проведено аналіз вибору датасету ACDC (Automated Cardiac Diagnosis Challenge) для сегментації зображень серця. Використання цього датасету вважається обґрунтованим через його різноманітність та репрезентативність клінічних випадків. Використання датасету ACDC являється обґрунтованим, оскільки він надає різноманітні дані з магніто-резонансного зображення серця, що важливо для навчання та оцінки алгоритму сегментації.

Також був проаналізований формат даних зображень серця у вигляді NIfTI (Neuroimaging Informatics Technology Initiative) через його стандартність та можливість збереження просторової інформації. Використання формату NIfTI для зображень серця є перевагою, оскільки він є стандартом у галузі медичної обробки зображень, що полегшує обмін та обробку даних. Даний дозволяє зберігати важливу просторову інформацію, що є критично важливою для точної сегментації зображень серця.

Розроблений метод сегментації успішно адаптовано до зображень магніто-резонансного аналізу серця, враховуючи особливості цих зображень та використовуючи архітектурні покращення для досягнення найкращих результатів. Важливо враховувати архітектурні вдосконалення, які можуть включати в себе зміни в енкодері, декодері та функціях з'єднання, для досягнення найкращих результатів на МРТ-зображеннях серця. Адаптований метод є ефективним і відповідає вимогам сучасної медичної обробки зображень.

## **Розділ 4. Експериментальні дослідження ефективності діагностики захворювань серця за аналізом зображень**

### **4.1 Ефективність мереж, навчених на наборах даних**

В процесі досліджень моделі були піддані навчанню за схемою, в якій дані розділені на 80% для навчання і 20% для тестування. Об'єднаний набір даних включав ті ж самі дані, що і два інших набори, але він був об'єднаний. Ефективність моделі оцінювали шляхом проведення сегментації на тестовому наборі та порівняння з істинною сегментацією. Для оцінки використовували два показники: точність та F-міра класифікації пікселів міокарда при середній оцінці контурів міокарда. Окремі тести проводилися на систолічному і діастолічному тестових наборах.

Об'єднані дані виявилися більш ефективними, навіть у порівнянні з систолічним та діастолічним наборами, щонайменше у середньому. Це підтверджує важливість продовження навчання, використовуючи виключно об'єднаний набір даних при використанні архітектури Segnet .

У таблиці 4.1 представлені результати оцінювання за участю невеликого навчального набору. Використання меншого навчального набору суттєво знижує продуктивність. Отримані результати підтверджують перевагу об'єднаної мережі над двома іншими.

Мережі були названі відповідно до набору даних, на якому вони були навчені. Оцінки представляють собою середні значення класифікації мережею класу міокард на повному тестовому наборі. Ефективність мереж, навчених на великому навчальному наборі.

На основі архітектури Segnet було навчено модель на об'єднаному наборі даних, використовуючи ті самі навчальні та тестові дані, що й для U-net. Навчання тривало 50 епох зі зменшенням базової швидкості навчання в 8 разів кожні 7 епох. Також використовувалася аналогічна схема, але зі зменшеною кількістю епох для уповільнення процесу навчання.

Таблиця 4.1 – Ефективність мереж, навчених на наборах даних відносно одного класу

Набір даних	Тип мережі	Точність	F-міра
Систолічний	Unet	0.92	0.45
	Segnet	0.94	0.49
Діастолічний	Unet	0.91	0.47
	Segnet	0.93	0.50
Разом	Unet	0.91	0.53
	Segnet	0.93	0.55

Таке ж навчання проводилося на меншій навчальній вибірці, використовуючи 96% даних для навчання та 6% для тестування. У всіх інших аспектах процесу навчання та оцінювання використовувалися ті ж самі підходи, що й для вищезгаданого, більшого навчального набору.

Модель також навчалася на наборі даних з розбиттям за допомогою тієї самої схеми, яку використовувалася для Segnet . Після чого мережу оцінювали за аналогічними критеріями на тестових вибірках. Результати оцінки Segnet подані в таблиці 4.2, разом із відповідними показниками.

Оцінка ефективності проводилася як для більшого, так і для меншого поділу даних на навчальні і тестові. Результати представлені у вигляді середніх оцінок класифікації мережею класу "Міокард" на повному тестовому наборі.

Функція винагороди розраховується як сума різниці винагороди за індексом подібності, винагороди за відстань до краю та винагороди за кластеризацію точок. З метою підтвердження позитивного впливу винагороди за відстань до краю та кластеризацію точок, в останньому експерименті для навчання майже не використовувалася винагорода за різницю в індексі подібності як остаточна негайна винагорода. Варто відзначити, що стан складається з п'яти шарів, аналогічно експерименту 0.

Таблиця 4.2 – Оцінка ефективності мереж Unet і Segnet, навчених на об'єднаному наборі даних для більшої множини даних для навчання

Набір даних	Тип мережі	Точність	F-міра
Систолічний	Unet	0.94	0.49
	Segnet	0.95	0.51
Діастолічний	Unet	0.94	0.52
	Segnet	0.95	0.55
Разом	Unet	0.93	0.53
	Segnet	0.95	0.55

Порівнюючи дані експерименту, можна відзначити, що різниця у винагороді за індексом подібності збільшується, якщо відкинути винагороду за відстань до краю і винагороду за кластеризацію точок. Однак загальна винагорода і середня F-міра як у процесі навчання, так і в процесі тестування зменшуються. Використання винагороди за різницю в індексі подібності як остаточної безпосередньої винагороди призвело лише до досягнення 0,55 F-міри на тестовому наборі даних, як показано в таблиці. Це свідчить про різке зменшення на 20% у порівнянні з використанням суми винагороди за різницю в індексі подібності, винагороди за відстань до краю та винагороди за кластеризацію точок. Таким чином, можна зробити висновок, що додавання винагороди за відстань до межі та винагороди за кластеризацію точок сприяє отриманню більш комплексної оцінки. Зміни в критеріях оцінюються відповідно до епох навчання в процесі роботи з навчальним набором даних ACDC.

Спостерігається перевага Segnet над Unet у відношенні ефективності, особливо коли Segnet навчено на великому навчальному наборі даних. Важливо відзначити, що Segnet, навчений на цьому об'ємному наборі даних, досягнув більшого результату за меншу кількість епох порівняно з відповідним Unet.

## 4.2 Формування сегментованих контурів

Для детального візуального аналізу були виокремлені контури за допомогою системи, що детально описана в попередніх розділах. Сегментовані контури наведено поруч з відповідними справжніми контурами на зображеннях. Цей процес визначення контурів виявив важливу роль у визначенні границь структур та анатомічних елементів на зображеннях, надаючи важливі візуальні дані для подальших аналізів і вдосконалення методів обробки. Результати цього візуального аналізу дозволили провести докладну оцінку ефективності використаних алгоритмів та моделей в задачі сегментації об'єктів на зображеннях.

Зображення, використані для вивчення та аналізу, були отримані з набору даних ACDC – Automated Cardiac Diagnosis Challenge. За допомогою цих зображень проводилися експерименти та тестування, спрямовані на оцінку ефективності розроблених методів та моделей в контексті сегментації структур серця на медичних знімках.




Рисунок 4.1 – Базове зображення та форма дослідження набру даних ACDC

Зразки сегментованих контурів, взяті з вихідних зображень та фрагментів дослідження, представлено на рисунках 4.2 – 4.4.




Рисунок 4.2 – Сегментовані контури зображення серця: а) вихідне зображення серця; б) зображення досліджуваного фрагменту; в) зображення серця з сегментованими контурами

Контур зображення, що відображає попередні м'язи лівого шлуночка, наочно демонструє переваги використання Segnet . Добре визначена границя діастолічного зображення зі змінною шириною міокарда є результатом успішної роботи спеціалізованого Segnet. Діастолічний зріз зображення вражає своїм чітким контуром епікарда з усіх сторін, незважаючи на варіації інтенсивності за межами міокарда з різних напрямків.




Рисунок 4.3 – Сегментовані контури зображення серця: а) вихідне зображення серця; б) зображення досліджуваного фрагменту; в) зображення серця з сегментованими контурами

На зображенні діастолічного зрізу, що знаходиться поблизу основи серця та відображає область із невеликою площею міокарда, було помічено, що контур епікарда виходить за межі істинного контуру. У цьому конкретному випадку порівняння використання Segnet і Unet показало подібний індекс точності, але різні значення оцінки F-міри. Це стає очевидним при визначенні на зображеннях, де контур, отриманий від Segnet, більше відповідає дійсному стану.

Такі випадки викликають обґрунтовані обговорення та вивчення результатів, щоб краще зрозуміти, як алгоритми сегментації поведуться в умовах обмежень та особливостей медичних зображень.




Рисунок 4.4 – Сегментовані контури зображення серця: а) вихідне зображення серця; б) зображення досліджуваного фрагменту; в) зображення серця з сегментованими контурами

На діастолічному зрізі, навіть при низькому контрасті, спостерігається успішне окреслення контуру, що свідчить про ефективність використання відповідного методу сегментації. Однак, на іншому діастолічному зображенні, виникає проблема з контуром, представлена у вигляді темних плям у лівому

шлуночку. Це може вказувати на те, що певні умови або особливості зображення можуть впливати на точність сегментації.

З метою забезпечення кращого візуального сприйняття меж границь зрізів зображень, вони були представлені у збільшеному вигляді на рисунках 4.5 та 4.6.




Рисунок 4.5 – Збільшене зображення сегментованих контурів серця




Рисунок 4.6 – Збільшене зображення сегментованих контурів серця

Діастолічний, зернистий зріз зображення поблизу основи серця показав випадок, де Segnet має проблеми з розмежуванням, тоді як Unet виявився менш ефективним у порівнянні зі спеціалізованим Segnet .

На зрізі систолічного зображення поблизу основи серця знову можна відзначити проблему окреслення епікарда та тенденцію до занадто сильного витягування контуру. Це може бути ключовими аспектами, які потребують уваги та вдосконалення для досягнення більш точної сегментації в подібних умовах.

Аналіз індивідуальних випадків та аномалій у роботі алгоритмів сегментації дозволяє здійснити фінішні налаштування та вдосконалення для оптимальної ефективності в різних умовах зображень серця.

Для візуальної оцінки роботи мережі, були використані два кольори: зелений відображає контур, який був визначений мережею Segnet, тоді як червоний відображає контур, отриманий мережею Unet. Зображення були вибрані для відображення певної поведінки моделей або для підкреслення відмінностей у характеристиках різних мереж.

Це дозволяє детальніше розглядати контури та порівнювати їхню відповідність між різними моделями.

Розмежування були виконані окремими мережами для систолічних і діастолічних зображень з використанням як мережі Segnet, так і Unet.

Індивідуальні оцінки точності та F-міри для кожного зображення представлені для порівняння та для відображення характеру цих оцінок. Це дозволяє докладніше аналізувати ефективність кожної моделі та порівнювати їхні результати.

### **4.3 Оцінювання втрат при навчанні моделей**

Мінімізація функції втрат є індикатором ходу навчання. Однак вона не обов'язково є мірою ефективності отриманої моделі, яку в ідеалі хотіли б відстежувати в процесі навчання. Однак функція втрат має давати змогу робити висновки про характер різних мереж та їхню ефективність. На рисунку 4.7 показано функцію втрат у процесі навчання Segnet та для мережі Unet на рисунку 4.8.

Функція втрат для кожної ітерації в процесі навчання у вигляді середніх втрати за епоху.




Рисунок 4.7 – Середні показники функції втрат втрати за епоху для мережі Segnet

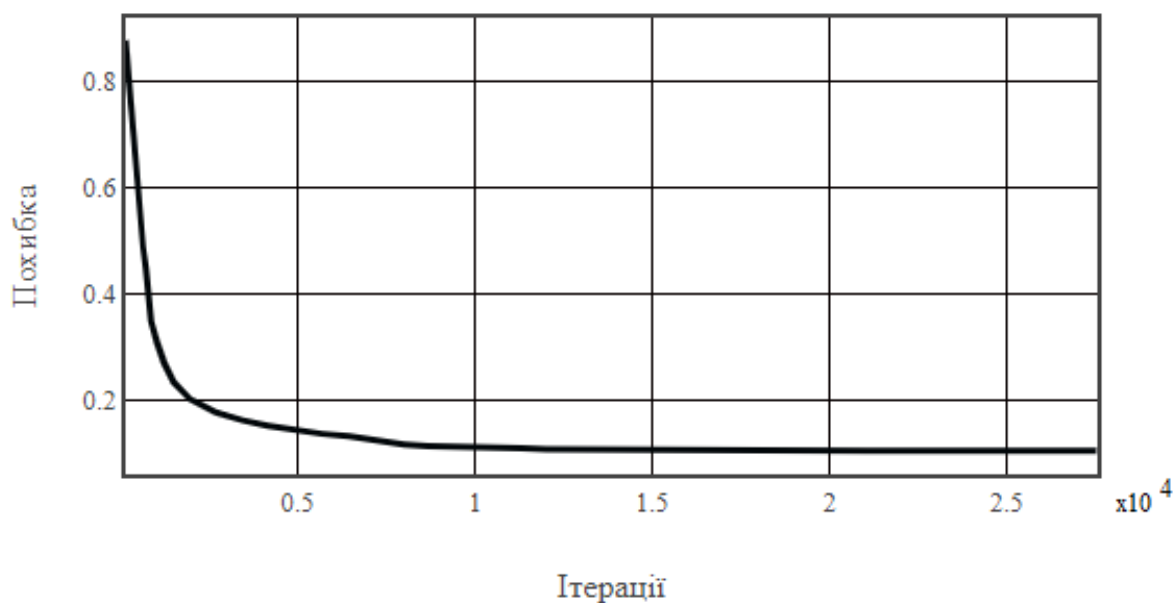


Рисунок 4.8 – Середні показники функції втрат втрати за епоху для мережі Unet

На рисунках похибка для мереж, навчених на наборах даних. Важливо зазначити, що кількість ітерацій залежить від кількості епох навчання і розміру пакета. Для навчання Segnet використовується вдвічі менший розмір пакета, ніж для Unet, а для великого набору даних лише 60 епох, що призводить до різної кількості ітерацій.

Для обмеженого обсягу даних графіки функцій втрат ілюструють ефективність мереж. Ці графіки сходяться до більших значень функції втрат порівняно з великим набором даних, що свідчить про те, що досягнута моделлю оптимізація не досягає того ж рівня, що й у випадку більшого набору даних. Більший успіх об'єднаної мережі в цьому випадку, ймовірно, є наслідком більшого обсягу навчальних даних, оскільки окремі набори даних ведуть до ще меншої оптимізації моделі. З іншого боку, при використанні великого набору навчальних даних досягнуті втрати не значно відрізняються між різними наборами даних. Однак на обмеженому обсягу даних Segnet досягає мінімуму і демонструє хорошу ефективність сегментації. Це свідчить про те, що Segnet може бути навчений на меншому обсягу даних, що полегшує вивчення набору даних і підтверджує його репрезентативність для відображення структури міокарда.

Також важливо враховувати можливість використання спеціалізованих мереж для різних частин серця, наприклад, для базальних або апікальних зрізів, що, в разі їх розділу, дозволить отримати менший набір даних. Тут нарощування масиву даних може бути дуже корисним.

Під час оцінювання сегментації рекомендується використовувати взаємодоповнюючі заходи. Важливо зрозуміти, що саме ці заходи включають в себе. Візуальний огляд сегментації відіграє важливу роль у розумінні продуктивності, переваг і обмежень мережі.

Ця архітектура та методика можуть бути легко адаптовані для вирішення аналогічних задач сегментації, таких як сегментація інших органів тіла, а також для застосування різних методів візуалізації. Це можливо здійснити досить швидко, витративши лише зусилля на створення набору даних. Підхід

послужить основою для майбутніх застосувань глибокого навчання в області МРТ серця та дозволить швидко перевірити його ефективність для різних завдань сегментації. Досвід роботи з платформами глибокого навчання буде корисним у навчанні для майбутніх проектів і допоможе скоротити часові і ресурсні витрати.

Незважаючи на переваги, існують певні обмеження та проблеми з системою та мережами, які виходять за рамки даної роботи. Ці аспекти можуть стати предметом подальших досліджень та вдосконалення в майбутніх проектах.

Розмір кадрування виявився надто обмеженим для деяких сценаріїв тому необхідно провести дослідження для визначення оптимального мінімального розміру кадру, який завжди забезпечить повний захват міокарда. Після отримання цього розміру необхідно обрізати всі зображення до цієї стандартної величини.

У наборі даних виявили приклади зрізів, які можуть вважатися прикордонними для середнього шлуночка. Необхідно провести ретельний аналіз та розподілити дані на базальні, апікальні та середні зрізи шлуночка. Це надасть можливість провести дослідження, аналогічне тому, яке було виконано для комбінації кінцевих діастолічних і систолічних зрізів. Такий підхід дозволить отримати більше висновків та розуміння для різних частин серця.

Це розширення дослідження спрямоване на поліпшення підходу та робить можливим врахування різноманітності морфології серця у різних його частинах.

Метод, що базується на класифікації пікселів, проявляє ефективність у визначенні різних класів, наприклад, у відео зі сценою руху. Проте, для сегментації міокарда, де дискретне віднесення кожного пікселя до класу міокарда чи фону не завжди є найоптимальнішим, особливо при низькій роздільній здатності зображень. У випадках, коли впевненість у класифікації пікселя невелика, краще намалювати контур через піксель, засновуючись на вихідних даних зі шару `softmax`, ніж привласнювати йому дискретний клас.

З метою уникнення невизначеності, що впливає з дискретної класифікації пікселів, планується використання контуру, отриманого безпосередньо з виходу шару softmax.

Експерименти з різними архітектурами мереж, схемами навчання та методами доповнення даних залишаються відкритими для дослідження. Додатковим кроком у вдосконаленні моделі може бути використання більш конкретних міток при маркуванні зображень, наприклад, позначення пікселів, які відносяться до лівого чи правого шлуночка.

Вивчення питання про те, чи слід використовувати загальні мережі, навчені на всіх зрізах зображення, чи краще розділити їх на середньошлуночкові зрізи, надає уявлення про те, як ефективно працювати з різноманітним набором даних.

Для подальших досліджень може бути корисним навчати загальну модель на різноманітному наборі даних і налаштовувати її для кожного конкретного випадку. Виявляється, що загальний підхід є більш перспективним, і його можна адаптувати для роботи з окремими мережами, налаштованими під конкретний набір даних.

У процесі навчання мережі тестують на валідаційній множині, що є окремою від навчальної та тестової множин. Перехід від використання індексів пулінгу до використання пропускних з'єднань у структурі архітектури виглядає перспективним для отримання більш точного контуру. Хоча це може призвести до збільшення обсягу використовуваної пам'яті, це не є проблемою, оскільки в даному випадку немає жорстких вимог щодо швидкості обробки.

#### **Висновки до розділу 4**

В даному розділі досліджено підхід, заснований на класифікації за пікселями, для задачі сегментації, зокрема в контексті визначення міокарда на медичних зображеннях. Виявлено, що при невеликій впевненості у класифікації пікселя може бути ефективніше провести контур через піксель, використовуючи

вихід шару softmax, ніж робити дискретні віднесення до класів. Це особливо актуально при низькій роздільній здатності зображення.

Досліджено можливість поліпшення моделі через експерименти з різними мережевими архітектурами, схемами навчання та доповненнями даних. Також розглянуто питання маркування зображень більш конкретними мітками для покращення точності моделі.

Проведено роздільне дослідження використання загальних мереж, навчених на всіх зрізах зображення, та розділених на базальні, апікальні та середньошлуночкові зрізи. Далі реалізовано можливість навчання загальної моделі на різноманітному наборі даних та налаштування її для конкретних випадків. Зазначено, що в процесі навчання модель тестується на валідаційній множині, окремій від тренувальної та тестової множин. Розглянуто перспективу заміни передавання індексів пулінгу на пропускні з'єднання для отримання більш точного контуру, при цьому зазначено можливий недолік у збільшенні обсягу пам'яті. У подальших дослідженнях слід розглядати можливість використання більш конкретних міток при маркуванні зображень, наприклад, виділення пікселів, які належать до лівого і правого шлуночків. Це може сприяти покращенню точності сегментації та дозволити моделі краще розрізняти між різними структурами міокарда.

Важливо дослідити різні підходи до обробки зображень з різних перспектив, таких як базальні, апікальні та середньошлуночкові зрізи. Розглянуто можливості навчання загальної моделі на різноманітних даних та її подальше налаштування на конкретних наборах, що може допомогти забезпечити універсальність підходу.

Узагальнюючи, подальші дослідження повинні бути спрямовані на комплексний аналіз різних аспектів, які впливають на ефективність та точність сегментації міокарда, з метою покращення якості результатів та стійкості моделі в різних умовах..

## Загальні висновки

Розроблена модель сегментації лівого шлуночка серця з використанням глибокого навчання успішно впоралася з основним завданням проекту. Модель продемонструвала хороші результати, ефективно сегментуючи міокард у багатьох випадках, включаючи важкодоступні частини, такі як папілярні м'язи. Навчання мережі дозволило враховувати не лише границі інтенсивності, але і можливі темні плями в лівому шлуночку. Мережа вдало враховує наявність темних плям, що в лівому шлуночку, що свідчить про її здатність адаптуватися до різних умов. Важливо відзначити, що модель навчилася розпізнавати ендокард як при наявності, так і при відсутності папілярних м'язів, підтверджуючи універсальність її застосування.

Модель проявила інваріантність до масштабу, здатність ефективно сегментувати міокард різних розмірів. Варто відзначити, що випадки меншого розміру міокарда часто призводять до більш хорошої сегментації зовнішньої межі. Додавання більшого розмаїття товщини стінок міокарда до навчального набору може коригувати цю масштабну інваріантність, роблячи модель більш універсальною і покращуючи її взаємодію з різними розмірами.

У контексті завдання сегментації міокарда важливим виявилось використання змішаного навчального набору, який включав зображення із кінцевої систолічної і кінцевої діастолічної фаз часового циклу серця. Такий підхід призвів до створення належної моделі, яка працює ефективно і на різних наборах даних. Загальна модель проявила себе краще, ніж конкретні моделі, навіть на специфічних наборах даних. Це може пояснюватися тим, що конкретні моделі, імовірно, занадто вагомо враховують навчальні дані, що може обмежити їхню універсальність в контексті властивостей міокарда загалом.

Інша можлива причина може полягати в тому, що зображення в наборі даних, що викликає погане навчання, стає менш проблематичною величиною в контексті більшого набору даних. Однак важливо враховувати використання партій під час навчання. На перший погляд може здаватися, що конкретні набори

даних мають ефективніше навчати модель на конкретних даних. Однак важливішими можуть бути заходи для запобігання перенавчанню та іншим можливим причинам. Справедливо вважати, що в даному випадку використання повного набору даних є доцільним першим кроком на шляху до розробки моделі, яка працює ефективно.

Інша можлива причина, яку варто розглянути, полягає в тому, що зображення в конкретному наборі даних може викликати погане навчання через його обмежену репрезентацію в контексті більшого набору даних. Це може пояснювати те, чому модель видає неадекватні результати на цьому конкретному наборі.

Важливо враховувати використання партій під час навчання. Якщо конкретний набір даних не представляє достатньої різноманітності або важкості для моделі, використання партій може допомогти урізноманітнити градієнти та поліпшити загальний процес навчання. Партії допомагають у вивченні різних аспектів даних та підвищують стійкість моделі до різних умов.

На перший погляд, може здаватися, що конкретні набори даних ефективніше навчають модель на конкретних даних. Однак, важливо пам'ятати, що успішність моделі в більш широкому контексті може залежати від її загальної здатності до узагальнення, тобто здатності працювати ефективно на нових та різноманітних даних, які не входять в навчальний набір.

Заходи для запобігання перенавчанню та іншим можливим причинам, таким як аугментація даних, регуляризація та вибір оптимальних алгоритмів оптимізації, можуть бути важливими для покращення результатів моделі на конкретному наборі даних. Такий підхід допомагає створити модель, яка добре взаємодіє з реальними умовами та володіє високою загальною ефективністю.

## Перелік посилань

1. Al'Aref S. J., Anchouche K., Singh G., Slomka P. J., Kolli K. K., Kumar A., Pandey M., Maliakal G., Rosendaal A. R. van, Beecy A. N., Berman D. S., Leipsic J., Nieman K., Andreini D., Pontone G., Schoepf U. J., Shaw L. J., Chang H.-J., Narula J., Bax J. J., Guan Y., Min J. K. Clinical applications of machine learning in cardiovascular disease and its relevance to cardiac imaging. *European Heart Journal*. 2019. Vol. 40, No. 24. Pp. 1975–1986. URL: <https://doi.org/10.1093/eurheartj/ehy404>.
2. Asgari Taghanaki S., Abhishek K., Cohen J. P., Cohen-Adad J., Hamarneh G. Deep semantic segmentation of natural and medical images: a review. *Artificial Intelligence Review*. 2021. Vol. 54, No. 1. Pp. 137–178. URL: <https://doi.org/10.1007/s10462-020-09854-1>.
3. Avendi M. R., Kheradvar A., Jafarkhani H. Automatic segmentation of the right ventricle from cardiac MRI using a learning-based approach. *Magnetic resonance in medicine*. 2017. Vol. 78, No. 6. Pp. 2439–2448.
4. Bai Q., Li S., Yang J., Song Q., Li Z., Zhang X. Object Detection Recognition and Robot Grasping Based on Machine Learning: A Survey. *IEEE Access*. 2020. Vol. 8. Pp. 181855–181879. URL: <https://doi.org/10.1109/ACCESS.2020.3028740>.
5. Cui H., Wang Y., Li Y., Xu D., Jiang L., Xia Y., Zhang Y. An Improved Combination of Faster R-CNN and U-Net Network for Accurate Multi-Modality Whole Heart Segmentation. *IEEE Journal of Biomedical and Health Informatics*. 2023.
6. Doyle C. M., Orr J., Greenwood J. P., Plein S., Tsoumpas C., Bissell M. M. Four-dimensional flow magnetic resonance imaging in the assessment of blood flow in the heart and great vessels: A systematic review. *Journal of Magnetic Resonance Imaging*. 2022. Vol. 55, No. 5. Pp. 1301–1321.
7. Elhoseny M. Multi-object Detection and Tracking (MODT) Machine Learning Model for Real-Time Video Surveillance Systems. *Circuits, Systems, and*

*Signal Processing*. 2020. Vol. 39, No. 2. Pp. 611–630. URL: <https://doi.org/10.1007/s00034-019-01234-7>.

8. Fuchs F. D., Whelton P. K. High blood pressure and cardiovascular disease. *Hypertension*. 2020. Vol. 75, No. 2. Pp. 285–292.

9. .

10. Holbek S., Hansen K. L., Bouzari H., Ewertsen C., Stuart M. B., Thomsen C., Nielsen M. B., Jensen J. A. Common carotid artery flow measured by 3-D ultrasonic vector flow imaging and validated with magnetic resonance imaging. *Ultrasound in medicine & biology*. 2017. Vol. 43, No. 10. Pp. 2213–2220.

11. Hosseini S. A. H., Moeller S., Weingärtner S., Uğurbil K., Akçakaya M. Accelerated coronary MRI using 3D SPIRiT-RAKI with sparsity regularization: 2019 *IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*, IEEE, 2019. Pp.1692–1695.

12. Ibanez B., Aletras A. H., Arai A. E., Arheden H., Bax J., Berry C., Bucciarelli-Ducci C., Croisille P., Dall'Armellina E., Dharmakumar R. Cardiac MRI endpoints in myocardial infarction experimental and clinical trials: JACC scientific expert panel. *Journal of the American College of Cardiology*. 2019. Vol. 74, No. 2. Pp. 238–256.

13. Inomata S., Yoshimura T., Tang M., Ichikawa S., Sugimori H. Estimation of Left and Right Ventricular Ejection Fractions from cine-MRI Using 3D-CNN. *Sensors*. 2023. Vol. 23, No. 14. Pp. 6580.

14. Irmawati D., Wahyunggoro O., Soesanti I. Comparing of CNN Algorithms for Feature Extraction and Classification on Cardiac MRI: 2022 *2nd International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, IEEE, 2022. Pp.375–380.

15. Jiang F., Grigorev A., Rho S., Tian Z., Fu Y., Jifara W., Adil K., Liu S. Medical image semantic segmentation based on deep learning. *Neural Computing and Applications*. 2018. Vol. 29, No. 5. Pp. 1257–1265. URL: <https://doi.org/10.1007/s00521-017-3158-6>.

16. Jin Z., Zhang Z., Ott J., Gu G. X. Precise localization and semantic segmentation detection of printing conditions in fused filament fabrication technologies using machine learning. *Additive Manufacturing*. 2021. Vol. 37. Pp. 101696. URL: <https://doi.org/10.1016/j.addma.2020.101696>.
17. Kan A. Machine learning applications in cell image analysis. *Immunology & Cell Biology*. 2017. Vol. 95, No. 6. Pp. 525–530. URL: <https://doi.org/10.1038/icb.2017.16>.
18. Khan M. Z., Gajendran M. K., Lee Y., Khan M. A. Deep Neural Architectures for Medical Image Semantic Segmentation: Review. *IEEE Access*. 2021. Vol. 9. Pp. 83002–83024. URL: <https://doi.org/10.1109/ACCESS.2021.3086530>.
19. Kording F., Yamamura J., De Sousa M. T., Ruprecht C., Hedström E., Aletras A. H., Ellen Grant P., Powell A. J., Fehrs K., Adam G. Dynamic fetal cardiovascular magnetic resonance imaging using Doppler ultrasound gating. *Journal of Cardiovascular Magnetic Resonance*. 2018. Vol. 20, No. 1. Pp. 1–10.
20. Madabhushi A., Lee G. Image analysis and machine learning in digital pathology: Challenges and opportunities. *Medical Image Analysis*. 2016. Vol. 33. Pp. 170–175. URL: <https://doi.org/10.1016/j.media.2016.06.037>.
21. Martin-Isla C., Campello V. M., Izquierdo C., Raisi-Estabragh Z., Baeßler B., Petersen S. E., Lekadir K. Image-Based Cardiac Diagnosis With Machine Learning: A Review. *Frontiers in Cardiovascular Medicine*. 2020. Vol. 7.
22. Mehrtash A., Ghafoorian M., Pernelle G., Ziaei A., Heslinga F. G., Tuncali K., Fedorov A., Kikinis R., Tempany C. M., Wells W. M. Automatic needle segmentation and localization in MRI with 3-D convolutional neural networks: application to MRI-targeted prostate biopsy. *IEEE transactions on medical imaging*. 2018. Vol. 38, No. 4. Pp. 1026–1036.
23. Mortazi A., Burt J., Bagci U. Multi-planar deep segmentation networks for cardiac substructures from MRI and CT: *Statistical Atlases and Computational Models of the Heart. ACDC and MMWHS Challenges: 8th International Workshop, STACOM 2017, Held in Conjunction with MICCAI 2017, Quebec City, Canada, September 10-14, 2017, Revised Selected Papers 8*, Springer, 2018. Pp.199–206.

24. Nurminen J. K., Rainio K., Numminen J.-P., Syrjänen T., Paganus N., Honkoila K. Object Detection in Design Diagrams with Machine Learning: *Progress in Computer Recognition Systems*, Cham , Springer International Publishing, 2020. Pp.27–36. URL: [https://doi.org/10.1007/978-3-030-19738-4\\_4](https://doi.org/10.1007/978-3-030-19738-4_4).
25. Österberg A. W., Östman-Smith I., Jablonowski R., Carlsson M., Green H., Gunnarsson C., Liuba P., Fernlund E. High ECG risk-scores predict late gadolinium enhancement on magnetic resonance imaging in HCM in the young. *Pediatric Cardiology*. 2021. Vol. 42. Pp. 492–500.
26. Paiman E. H., Lamb H. J. When should we use contrast material in cardiac MRI? *Journal of Magnetic Resonance Imaging*. 2017. Vol. 46, No. 6. Pp. 1551–1572.
27. Papageorgiou C., Poggio T. A Trainable System for Object Detection. *International Journal of Computer Vision*. 2000. Vol. 38, No. 1. Pp. 15–33. URL: <https://doi.org/10.1023/A:1008162616689>.
28. Qureshi I., Yan J., Abbas Q., Shaheed K., Riaz A. B., Wahid A., Khan M. W. J., Szczuko P. Medical image segmentation using deep semantic-based methods: A review of techniques, applications and emerging trends. *Information Fusion*. 2023. Vol. 90. Pp. 316–352. URL: <https://doi.org/10.1016/j.inffus.2022.09.031>.
29. Radau P., Lu Y., Connelly K., Paul G., Dick A. J., Wright G. A. Evaluation framework for algorithms segmenting short axis cardiac MRI. *The MIDAS Journal*. 2009.
30. Ramík D. M., Sabourin C., Moreno R., Madani K. A machine learning based intelligent vision system for autonomous object detection and recognition. *Applied Intelligence*. 2014. Vol. 40, No. 2. Pp. 358–375. URL: <https://doi.org/10.1007/s10489-013-0461-5>.
31. Saikumar K., Rajesh V. A novel implementation heart diagnosis system based on random forest machine learning technique. *International Journal of Pharmaceutical Research (09752366)*. 2020.
32. Salehi D., Sun L., Steding-Ehrenborg K., Bidhult S., Kording F., Ruprecht C., Macgowan C. K., Seed M., Aletras A. H., Arheden H. Quantification of blood flow in the fetus with cardiovascular magnetic resonance imaging using Doppler ultrasound

gating: validation against metric optimized gating. *Journal of Cardiovascular Magnetic Resonance*. 2019. Vol. 21. Pp. 1–15.

33. Shimpi P., Shah S., Shroff M., Godbole A. A machine learning approach for the classification of cardiac arrhythmia: *2017 International Conference on Computing Methodologies and Communication (ICCMC)*, July 2017. Pp.603–607. URL: <https://doi.org/10.1109/ICCMC.2017.8282537>.

34. Singh G., Al’Aref S. J., Van Assen M., Kim T. S., Rosendael A. van, Kolli K. K., Dwivedi A., Maliakal G., Pandey M., Wang J., Do V., Gummalla M., De Cecco C. N., Min J. K. Machine learning in cardiac CT: Basic concepts and contemporary data. *Journal of Cardiovascular Computed Tomography*. 2018. Vol. 12, No. 3. Pp. 192–201. URL: <https://doi.org/10.1016/j.jcct.2018.04.010>.

35. Sohail A., Nawaz N. A., Shah A. A., Rasheed S., Ilyas S., Ehsan M. K. A Systematic Literature Review on Machine Learning and Deep Learning Methods for Semantic Segmentation. *IEEE Access*. 2022. Vol. 10. Pp. 134557–134570. URL: <https://doi.org/10.1109/ACCESS.2022.3230983>.

36. Sun Z., Shen-Yuan L. A systematic review of 3-D printing in cardiovascular and cerebrovascular diseases. *Anatolian journal of cardiology*. 2017. Vol. 17, No. 6. Pp. 423–435.

37. Torrents-Barrena J., Piella G., Masoller N., Gratacós E., Eixarch E., Ceresa M., Ballester M. Á. G. Segmentation and classification in MRI and US fetal imaging: recent trends and future prospects. *Medical Image Analysis*. 2019. Vol. 51. Pp. 61–88.

38. Trivizakis E., Manikis G. C., Nikiforaki K., Drevelegas K., Constantinides M., Drevelegas A., Marias K. Extending 2-D convolutional neural networks to 3-D for advancing deep learning cancer classification with application to MRI liver tumor differentiation. *IEEE journal of biomedical and health informatics*. 2018. Vol. 23, No. 3. Pp. 923–930.

39. Wäldchen J., Mäder P. Machine learning for image based species identification. *Methods in Ecology and Evolution*. 2018. Vol. 9, No. 11. Pp. 2216–2225. URL: <https://doi.org/10.1111/2041-210X.13075>.

40. Wei-Wei C., Run-Lin G. A. O., Li-Sheng L. I. U., Man-Lu Z. H. U., Wen W., Yong-Jun W., Zhao-Su W. U., Hui-Jun L. I., Dong-Feng G. U., Yue-Jin Y. China cardiovascular diseases report 2015: a summary. *Journal of geriatric cardiology: JGC*. 2017. Vol. 14, No. 1. Pp. 1.
41. Wilkins E., Wilson L., Wickramasinghe K., Bhatnagar P., Leal J., Luengo-Fernandez R., Burns R., Rayner M., Townsend N. European cardiovascular disease statistics 2017. 2017.
42. Wu B., Fang Y., Lai X. Left ventricle automatic segmentation in cardiac MRI using a combined CNN and U-net approach. *Computerized Medical Imaging and Graphics*. 2020. Vol. 82. Pp. 101719.
43. Yang R., Yu Y. Artificial Convolutional Neural Network in Object Detection and Semantic Segmentation for Medical Imaging Analysis. *Frontiers in Oncology*. 2021. Vol. 11.
44. Zhao D., Liu J., Wang M., Zhang X., Zhou M. Epidemiology of cardiovascular disease in China: current features and implications. *Nature Reviews Cardiology*. 2019. Vol. 16, No. 4. Pp. 203–212.
45. Zotti C., Luo Z., Lalande A., Jodoin P.-M. Convolutional neural network with shape prior applied to cardiac MRI segmentation. *IEEE journal of biomedical and health informatics*. 2018. Vol. 23, No. 3. Pp. 1119–1128.
46. Zotti C., Luo Z., Humbert O., Lalande A., Jodoin P.-M. GridNet with automatic shape prior registration for automatic MRI cardiac segmentation: *Statistical Atlases and Computational Models of the Heart. ACDC and MMWHS Challenges: 8th International Workshop, STACOM 2017, Held in Conjunction with MICCAI 2017, Quebec City, Canada, September 10-14, 2017, Revised Selected Papers 8*, Springer, 2018. Pp.73–81.

# ДОДАТКИ

## Додаток А

*Актуальні проблеми комп'ютерних наук*

---

УДК 004.4

Уваров В.С., Чабан О.Р., Манзюк Е.А.

*Хмельницький національний університет*

### **МЕТОД ДІАГНОСТИКИ ЗАХВОРЮВАНЬ СЕРЦЯ НА ОСНОВІ АНАЛІЗУ ЗОБРАЖЕНЬ, ОТРИМАНИХ МЕТОДОМ МАГНІТНО-РЕЗОНАНСНОЇ ТОМОГРАФІЇ**

*Створена та реалізована система для діагностики захворювань серця за допомогою аналізу зображень отриманих з магнітно-резонансної томографії (МРТ) з високою точністю, використовуючи нейромережеві підходи та інтелектуальний аналіз даних. У рамках дослідження використовувалися методи, які ґрунтуються на навчанні нейромереж на прикладах зображень серця пацієнта, а також методи, що використовують аналіз зображень для виявлення аномалій та відхилень в роботі серця. У розробленій системі існують механізми візуалізації та інтерпретації результатів нейромережі. Це може включати в себе відображення та пояснення ключових зон аномалій або патологічних змін на МРТ-зображеннях, виділення певних анатомічних особливостей та вказівників, які призвели до діагнозу.*

*A system has been developed and implemented for the diagnosis of heart diseases using high-precision analysis of images obtained from magnetic resonance imaging (MRI) with the utilization of neural network approaches and intelligent data analysis. Within the research framework, methods were employed that relied on training neural networks on examples of both healthy and heart disease-afflicted patients, as well as methods that utilized data-driven image analysis to detect anomalies and deviations in heart function. In the developed system, there are mechanisms for visualizing and interpreting the neural network's results. This may include displaying and explaining key areas of anomalies or pathological changes on MRI images, highlighting specific anatomical features and indicators that led to the diagnosis.*

Серцево-судинні захворювання протягом багатьох років залишаються однією з провідних причин смертності у всьому світі. У сучасному світі, особливо в розвинених країнах, це питання стає надзвичайно актуальним для системи охорони здоров'я [2, 3]. В цьому контексті особливе значення приділяється методам візуалізації, які відіграють ключову роль у наданні точних діагнозів вчасно.

Для оцінки стану серця та його функціонування використовуються різні методи візуалізації, такі як ультразвукове дослідження, електрокардіографія та магнітно-резонансна томографія (МРТ). Ці методи вимагають об'єктивних та ефективних інструментів аналізу роботи серця. Особливо важливим завданням є визначення об'єму лівого шлуночка серця, що дозволяє вчасно виявляти можливе

збільшення серця, що може виникнути внаслідок серцевої недостатності. Лівий шлуночок відповідає за перекачування крові до великої частини організму, і тому його функція є вирішальною для загальної оцінки роботи серця [1, 5].

Наукові дослідження, які проводяться в цій галузі, спрямовані на аналіз зображень серця, отриманих за допомогою МРТ, з метою покращення діагностики та контролю за серцевими захворюваннями.

Оцінка функції серця вимагає особливих підходів, і однією із ключових задач є точне визначення об'єму лівого шлуночка серця [4]. Це має важливе значення, оскільки збільшення лівого шлуночка може свідчити про розвиток серцевої недостатності. Робота лівого шлуночка полягає в перекачуванні крові до значної частини організму.

У запропонованій системі спочатку проводиться передпроцесінг, що включає в себе операції обрізки та повторного відбору частини зображення. Ця послідовність дій призводить до отримання обробленого зображення, готового до подальшої передачі у мережу. Наступним етапом є пропускання цього зображення через навчену мережу, що призводить до виділення піксельного маркування міокарда та визначення пікселів фону (тобто всі пікселі, які не відносяться до міокарда).

Після цього проводиться пост-обробка отриманого маркування, результатом якої є формування контуру сегментованого міокарда та його подальше поєднання з вихідним зображенням. Ця система розроблена для потенційних користувачів, які мають намір використовувати її для виділення контуру міокарда на зображеннях.

Зображення спочатку піддається процедурі ресемплінгу, а потім проходить через підготовлену мережу для виділення центрального контуру, що оточує лівий шлуночок серця. Отримана сегментація має ті самі розмір та роздільну здатність, що й вихідне зображення, і контури відображаються поверх нього.

Ця мережа відзначається своєю повністю згортковою структурою, яка складається з двох ключових компонентів: кодувальної та декодувальної частин мережі. Кожен кодер співпрацює зі своїм відповідним декодером, створюючи потужний механізм для точного виділення контуру міокарда. Ця система призначена для користувачів, які мають намір використовувати її для медичних досліджень та діагностики, і вона допомагає автоматизувати та полегшити процес виділення контуру серця на зображеннях.

Кодери включають два або три згорткових блоки, кожен з ядрами згортувального шару розміром  $3 \times 3$ . Після кожного такого блоку слідує шар пакетної нормалізації та шар ReLU для активації. По завершенні кожного згорткового блоку застосовується шар макс-пулінгу з вікном розміром  $2 \times 2$  та кроком 2, що призводить до зменшення розмірності карти ознак. Важливим є те, що

кількість каналів ознак подвоюється після кожної дискретизації знижувальною функцією.

Індекси, які отримуються під час операцій макс-пулінгу, зберігаються та використовуються в декодерах. Декодери, в певному розумінні, можна розглядати як дзеркальні версії кодерів, але вони включають де-згорткові шари для розширення розмірності карти ознак, використовуючи індекси макс-пулінгу, отримані на етапі кодування.

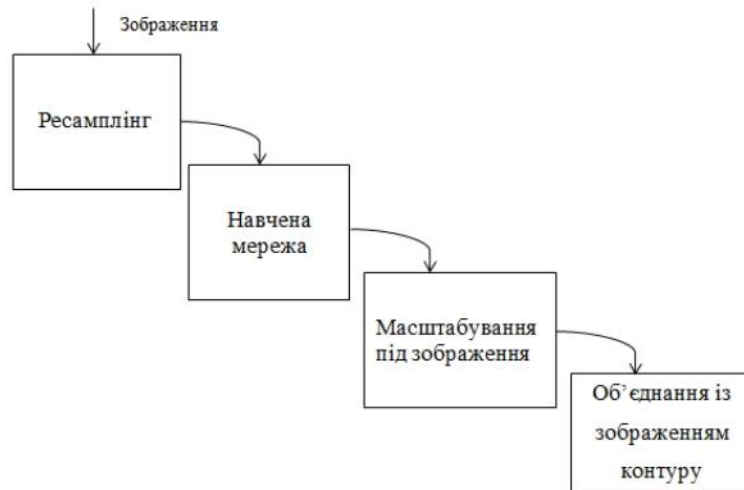


Рисунок 1 – Ілюстрація етапів роботи пропонованої системи для сегментації міокарда

Архітектура є модифікованою версією архітектури U-net, але відрізняється тим, що у кодерах завжди використовуються лише два блоки згорткових шарів. Важливою особливістю є те, що кількість каналів ознак залишається постійною, це відрізняє її і робить менш вимогливою до використання пам'яті ресурсів.

У результаті застосування глибокого навчання була створена модель для сегментації лівого шлуночка серця, що вдалося здійснити основну мету проекту. Ця модель продемонструвала хороші досягнення, успішно сегментуючи міокард у багатьох складних випадках, включаючи ситуації, коли присутні папілярні м'язи. Важливо зазначити, що мережі навчилися не лише визначати контури за інтенсивністю, але й розрізняти важкі сценарії, такі як поява темних ділянок у лівому шлуночку, і успішно інтегрують ці області у сегментацію лівого шлуночка.

Це демонструє важливість процесу навчання, де ознаки, що можуть бути важко реалізовані вручну в моделі, легко інтегруються через навчання. Мережа демонструє консистентну здатність виділяти ендокард, незалежно від наявності чи відсутності папілярних м'язів, що підкреслює її універсальність. Модель також проявляє інваріантність до масштабу та впорядковує сегментацію міокарда на зображеннях різного розміру. Однак, варто зауважити, що зовнішні межі, як правило, визначаються більш точно у випадках з меншими розмірами.

#### Перелік посилань

1. Barrett M., Boyne J., Brandts J., Brunner-La Rocca H.-P., De Maesschalck L., De Wit K., Dixon L., Eurlings C., Fitzsimons D., Golubnitschaja O. Artificial intelligence supported patient self-care in chronic heart failure: a paradigm shift from reactive to predictive, preventive and personalised care. *Epta Journal*. 2019. Vol. 10. Pp. 445–464.
2. Biofeedback D. Biofeedback: an overview in the context of heart-brain medicine. *Cleveland Clinic journal of medicine*. 2008. Vol. 75. Pp. S31.
3. Johnston B. W., Barrett-Jolley R., Krige A., Welters I. D. Heart rate variability: Measurement and emerging use in critical care medicine. *Journal of the Intensive Care Society*. 2020. Vol. 21, No. 2. Pp. 148–157.
4. Kwon J., Kim K.-H., Jeon K.-H., Lee S. E., Lee H.-Y., Cho H.-J., Choi J. O., Jeon E.-S., Kim M.-S., Kim J.-J. Artificial intelligence algorithm for predicting mortality of patients with acute heart failure. *PloS one*. 2019. Vol. 14, No. 7. Pp. e0219302.
5. Sonawane A. R., Aikawa E., Aikawa M. Connections for matters of the heart: network medicine in cardiovascular diseases. *Frontiers in Cardiovascular Medicine*. 2022. Vol. 9. Pp. 873582.

## Додаток Б

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

### Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами

**Виконав:**

*студент групи КНМ-21-1*

Уваров В.С.

1

## Актуальність

Сучасні наукові дослідження в галузі кардіології націлені на систематичне удосконалення методів аналізу зображень серця, отриманих завдяки технології магнітно-резонансної томографії (МРТ). Ці дослідження, поглиблюючи розуміння механізмів функціонування серця, сприяють розробці нових методів діагностики та лікування серцевих захворювань. Такий підхід відкриває перспективи для підвищення ефективності медичної допомоги пацієнтам із серцевими патологіями.

Потреба у вдосконаленні точності та ефективності діагностики серцевих захворювань викликає необхідність подальших досліджень у сфері використання нейромереж для аналізу та інтерпретації зображень МРТ. Цей напрямок досліджень може відкрити нові можливості для точної та ранньої діагностики, покращуючи якість медичної допомоги пацієнтам із захворюваннями серця.

2

## Мета кваліфікаційної роботи

Метою кваліфікаційної роботи є вирішення науково-практичної задачі, розробки ефективного методу діагностики захворювань серця, заснованого на аналізі зображень отриманих з магнітно-резонансної томографії, використовуючи загорткову нейронну мережу для кращого визначення контурів та успішної адаптації до різних розмірів міокарда при локальній деталізації.

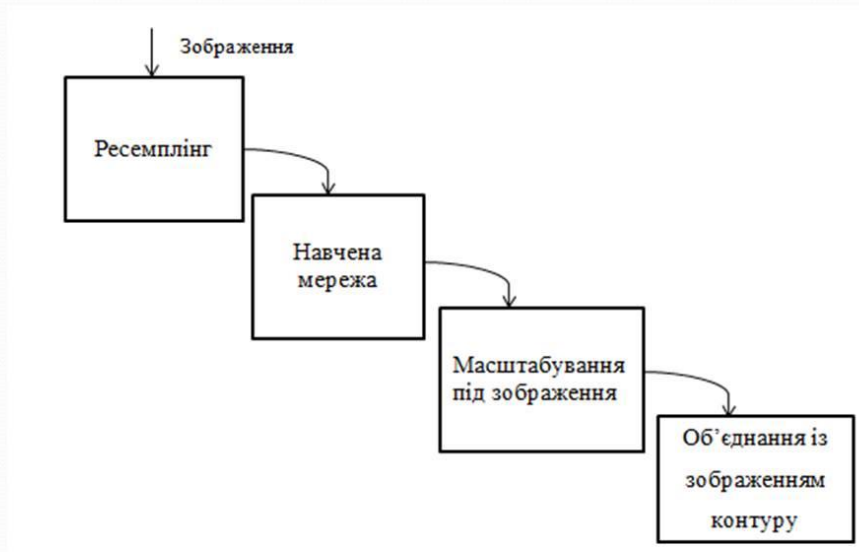
3

## Задачі роботи

1. Провести огляд наукових досліджень та публікацій в галузі діагностики захворювань серця, зосередженого на аналізі зображень з магнітно-резонансної томографії та використанні передових нейромережових технологій.
2. Розробити метод автоматизованої діагностики серцевих захворювань, що включає вдосконалене визначення контурів та адаптацію до різних розмірів міокарда через застосування нейромереж.
3. Адаптувати розроблений метод до різних розмірів міокарда, фокусуючись на локальній деталізації та враховуючи варіабельність зображень отриманих з магнітно-резонансної томографії.
4. Провести експериментальні випробування для оцінки ефективності та точності розробленого методу діагностики захворювань серця, використовуючи магнітно-резонансну томографію.

4

## Етапи роботи пропонуваної системи для сегментації міокарда




5

## Послідовність кроків при застосуванні методу (короткий опис)

- Крок 1. Збір та підготовка даних.
- Крок 2. Передпроцесінг зображення.
- Крок 3. Передача зображення через неймережу
- Крок 4. Пост-обробка результатів сегментації.
- Крок 5. Процедура ресемплінгу та редискретизації
- Крок 6. Адаптація та сегментація шлуночка.
- Крок 7. Визначення центральної точки шлуночка.
- Крок 8. Формування та проектування сегментації міокарда.
- Крок 9. Завершення та висновки.

6

## Архітектура Segnet




7

## Ефективність мереж, навчених на наборах даних відносно одного класу


Набір даних	Тип мережі	Точність (precision)	F-міра
Систолічний	U-net	0.92	0.45
	Segnet	0.94	0.49
Діастолічний	U-net	0.91	0.47
	Segnet	0.93	0.50
Разом	U-net	0.91	0.53
	Segnet	0.93	0.55

8

Сегментовані контури зображення серця: а) зображення серця з сегментованими контурами; б) зображення досліджуваного фрагменту.




а)




б)

9

Сегментовані контури зображення серця: а) зображення серця з сегментованими контурами; б) зображення досліджуваного фрагменту.




а)




б)

10

## Збільшене зображення сегментованих контурів серця




a)



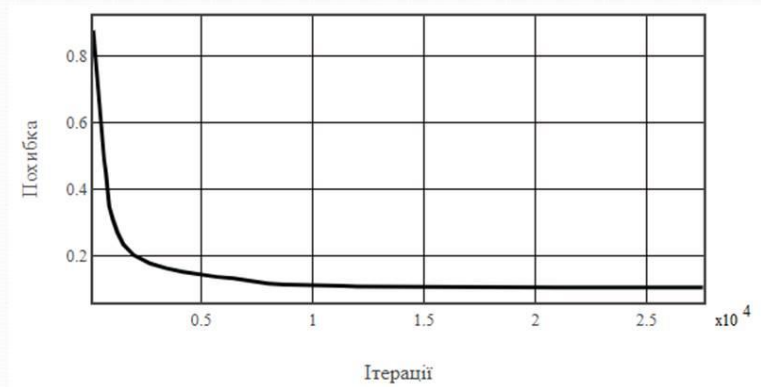
б)

11



Середні показники функції втрат втрапи за епоху для мережі Segnet

12



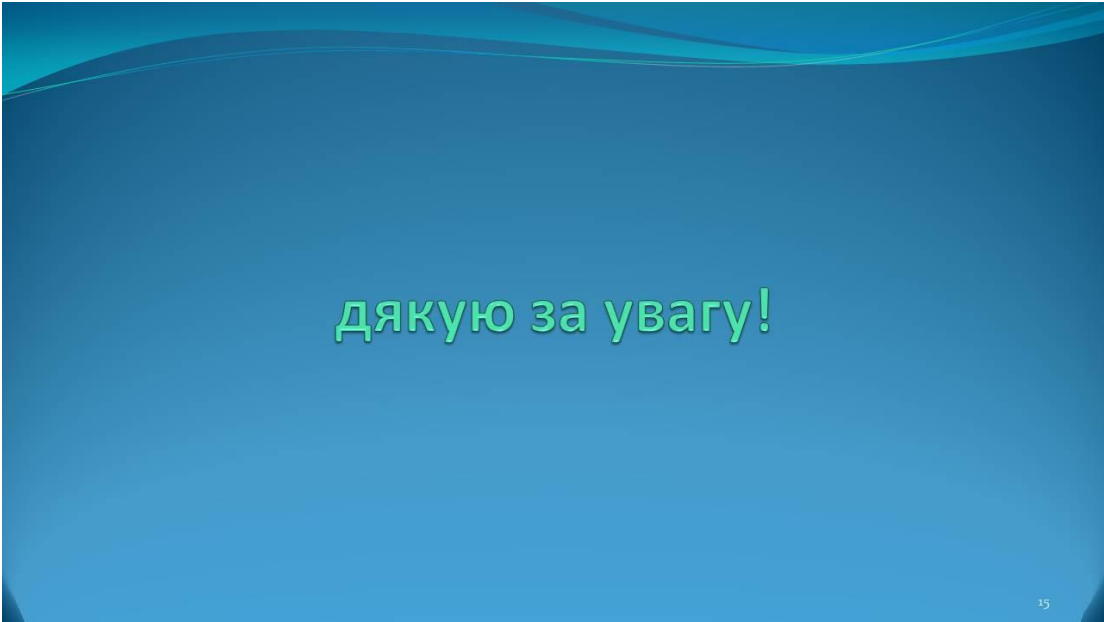
Середні показники функції втрат за епохи для мережі U-net

13

## Висновки

Розроблена модель сегментації лівого шлуночка серця з використанням глибокого навчання успішно впоралася з основним завданням проекту. Модель продемонструвала хороші результати, ефективно сегментуючи міокард у багатьох випадках, включаючи важкодоступні частини, такі як папілярні м'язи. Навчання мережі дозволило враховувати не лише границі інтенсивності, але і можливі темні плями в лівому шлуночку. Мережа вдало враховує наявність темних плям, що в лівому шлуночку, що свідчить про її здатність адаптуватися до різних умов. Важливо відзначити, що модель навчилася розпізнавати ендокард як при наявності, так і при відсутності папілярних м'язів, підтверджуючи універсальність її застосування.

14



дякую за увагу!

Ім'я користувача:  
Кафедра КН

ID перевірки:  
1015967917

Дата перевірки:  
04.12.2023 15:20:55 EET

Тип перевірки:  
Doc vs Internet + Library

Дата звіту:  
04.12.2023 15:24:31 EET

ID користувача:  
100005671

Назва документа: КНм-22-1 Уваров

Кількість сторінок: 77 Кількість слів: 17025 Кількість символів: 127774 Розмір файлу: 946.51 KB ID файлу: 1015646688

## 10.4% Схожість

Найбільша схожість: 1.02% з Інтернет-джерелом (<http://export.arxiv.org/pdf/2210.14909>)

10.3% Джерела з Інтернету

929

Сторінка 79

1.15% Джерела з Бібліотеки

53

Сторінка 86

## 0% Цитат

Вилучення цитат вимкнене

Не знайдено жодних посилань

## 0% Вилучень

Немає вилучених джерел

## Модифікації

Виявлено модифікації тексту. Детальна інформація доступна в онлайн-звіті.

Замінені символи

2

# Anti-Plagiarism v-15.257

**Максимальне співпадіння з одним документом 1.0%**

Словники перевірки: en\_US, ru\_RU, ua\_UA. **Помилоч в документах: 10%**

ID: 121717 Назва: КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами Додано в БД: 2023-12-04 Автора: В.С.Уваров Керівники: Е.А. Манзюк Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	104288	1624	1512 (1%)	27 (2%)

## Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

**РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК  
ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ**

Підтверджуємо ознайомлення з результатом звіту подібності щодо роботи, генерованого системою виявлення текстових збігів/ідентичності/схожості:

Назва: Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами

Автор: студент групи КНМ-22-1 Уварова Владислава Сергійовича

Спеціальність: 122 – Комп'ютерні науки

Освітня програма: освітньо-професійна

Науковий керівник: д.т.н., доцент Манзюк Е.А.

Після аналізу звіту подібності зроблено такий висновок:

№	Висновок	Позначка про відповідність
1	Запозичення, виявлені в роботі, є законними і не є плагіатом. Робота приймається до захисту.	<i>відповідає</i>
2	Виявлені запозичення не є плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота приймається до захисту, але має бути відкоригована. Відкоригований варіант має бути поданий на кафедру за 2 дні до захисту, разом із заявою щодо самостійності виконання письмової роботи та ідентичності друкованої та електронної версії роботи.	
3	Виявлені запозичення не є плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. В зв'язку з цим мета роботи та поставлені завдання не були досягнені. Робота може бути допущена до захисту (наступного року) після того як буде відкоригована та допрацьована і успішно пройде повторну перевірку на академічний плагіат.	
4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	

*Підтвердження:*

*Запозичення, виявлені в роботі Уварова В.С., не є плагіатом, оскільки: запозичення розміщені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; серед запозичень знаходяться загальновідомі терміни, скорочення.*

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

*- за системою Anti-Plagiarism: 1%;*

*- за системою Unichек: 10.4%.*

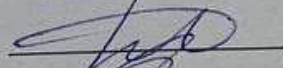
*Сумарний обсяг всіх запозичень, визначений системою виявлення збігів/ідентичності/схожості є допустимим.*

Керівник роботи



Едуард МАНЗЮК

Гарант ОП



Руслан БАГРІЙ

Завідувач кафедри КН



Олександр БАРМАК



## ВІДГУК ОПОНЕНТА

### на кваліфікаційну роботу магістра

студента *гр. КНМ-22-1 Уварова Владислава Сергійовича*

за темою *Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами*

#### 1. Актуальність обраної теми

Актуальність проведення дослідження з використанням методів машинного навчання в області кардіології визначається необхідністю покращення точності та ефективності діагностики серцевих захворювань. Сучасні виклики в галузі охорони здоров'я, зокрема серцево-судинних захворювань, створюють потребу в нових підходах до аналізу та інтерпретації зображень серця, отриманих за допомогою технології магнітно-резонансної томографії. Машинне навчання в цьому контексті може відігравати ключову роль у покращенні точності визначення стану серця, виявленні патологій та розробці нових методів діагностики та лікування. Тому обраний напрямок досліджень має потенціал в розробці ефективних стратегій діагностики та лікування серцевих захворювань.

#### 2. Відповідність роботи предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до наукових робіт

Тема роботи присвячена аналізу з зображень МРТ за допомогою нейромереж для діагностики серцевих захворювань повністю відповідає спеціальності 122 "Комп'ютерні науки" і всім критеріям для магістерської кваліфікаційної роботи.

#### 3. Повнота розкриття мети та завдань дослідження

У магістерській роботі детально висвітлено мету та конкретні завдання, забезпечуючи розкриття проблеми дослідження. Автор вдало визначив напрямки дослідження, що відображається у високій якості виконаної роботи та відповідності усім вимогам магістерського рівня.

#### 4. Наявність наукової новизни

Отримані результати відзначаються науковою новизною у сфері діагностики серцевих захворювань за допомогою методів обробки зображень МРТ з використанням нейромереж. Вдосконалено підхід до автоматичної сегментації міокарда на отриманих МРТ-зображеннях, де система здатна аналізувати об'ємні дані та точно визначати контур

серцевого м'яза. Це досягнення призводить до високої точності та ефективності сегментації, що відкриває нові можливості для автоматизованої та точної діагностики серцевих захворювань за допомогою неінвазивних методів зображення, зокрема МРТ. Результати дослідження сприяють поліпшенню точності та швидкості виявлення патологій серця. Результати дослідження оприлюднені на науково-практичній конференції.

#### **5. Зміст кожного розділу роботи**

Робота містить чотири розділи. В першому розділі присвячено огляду систем діагностування захворювань серця на основі аналізу зображень. Сформульовано мету та задачі дослідження. У другому розділі представлена розробка методу діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами. У третьому розділі представлена адаптація методу та застосування їх до множини даних. Четвертий розділ проведено експериментальним дослідження ефективності розробленого методу.

#### **6. Ступінь розкриття теми роботи**

Автор магістерської роботи ретельно обґрунтовує та розглядає тему свого дослідження, включаючи докладний аналіз актуальності та існуючих досліджень у відповідному напрямку. Виконані завдання були успішно завершені, і результати застосування розробленого методу детально проаналізовані з практичної точки зору.

#### **7. Якість оформлення кваліфікаційної роботи**


Оформлення наведеної роботи відповідає високим стандартам та вимогам, які визначаються для наукових кваліфікаційних робіт. Кожен аспект оформлення, включаючи структуру, опис методології, використання літературних джерел, та форматування, був детально врахований та ретельно дотриманий.

#### **8. Недоліки кваліфікаційної роботи**

Робота більшою мірою направлена на розробку методів машинного навчання в сфері предметної області. Для розширення роботи необхідно провести аналіз практичного застосування з врахуванням існуючих практик в медичній сфері.

#### **9. Загальний висновок (допускається чи не допускається до захисту), якої оцінки заслуговує кваліфікаційна робота**

Враховуючи рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка *добре*.

Рецензент зав. кафедр. АКТІТ та Р  В. Мергелиш



**ВІДГУК НАУКОВОГО КЕРІВНИКА  
на кваліфікаційну роботу магістра**

студента *гр. КНМ-22-1 Уварова Владислава Сергійовича*

за темою Метод діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами

**1. Актуальність теми**

Традиційні методи аналізу зображень мають обмеження при сегментації зображень, що вимагає значного досвіду та часу для вирішення нових завдань. Кожне нове завдання вимагає розробки свого власного алгоритму, ускладнюючи процес. З використанням машинного навчання можливо забезпечити більшу універсальність у вирішенні завдань сегментації зображень. Кваліфікаційна робота магістра розв'язує науково-практичну задачу розробки метода діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами.

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

Мета, яку було поставлено в магістерській кваліфікаційній роботі, полягала в розробці метода діагностики захворювань серця за аналізом зображень даних МРТ нейромережевими засобами. Ця мета повністю відповідає області комп'ютерних наук за спеціальністю 122 і відповідає вимогам до кваліфікаційної роботи.

**3. Професійні та особистісні якості**

Під час виконання магістерської кваліфікаційної роботи Владислав Сергійович Уваров виявив себе як студент із високою дисциплінованістю та кваліфікацією. Він якісно, вчасно та з великою увагою вирішував поставлені завдання. Його знання та навички достатні для досягнення високих результатів у відповідності до компетентностей обраної галузі.

**4. Ступінь самостійності під час виконання кваліфікаційної роботи**

Результати виконання кваліфікаційної роботи отримані студентом самостійно та висунуті положення сприяли удосконаленню методів автоматичного виявлення об'єктів з невеликою роздільною здатністю.

**5. Наукова новизна та оригінальність запропонованих підходів**

Новизна роботи полягає в удосконаленні методу діагностики серцевих захворювань за допомогою аналізу зображень МРТ з використанням нейромережеских

засобів. Основна увага спрямована на автоматичну сегментацію міокарда на отриманих МРТ-зображеннях. Інноваційність полягає у здатності методу обробляти великі обсяги МРТ-даних, точно визначати контур міокарда та чітко відобразити його на зображеннях. Цей підхід характеризується високою точністю та ефективністю сегментації, відкриваючи нові перспективи для автоматизованої та точної діагностики серцевих захворювань за допомогою неінвазивних методів, зокрема, МРТ.

**6. Ступінь оволодіння методами дослідження**

Магістрант успішно володіє необхідними методами дослідження.

**7. Повнота та якість розкриття теми роботи**

Тема роботи була повністю обґрунтована та розкрита. Проведено аналіз актуальності та існуючих досліджень у рамках обраної теми. Задачі, поставлені в роботі, були успішно виконані, і також проведено аналіз результатів використання розробленого методу.

**8. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу**

Організація структури роботи та викладення матеріалу відповідають визначеній меті. Подача інформації є послідовною, обґрунтованою та літературно грамотною.

**9. Можливість практичного застосування кваліфікаційної роботи, окремих її частин**

Отримана модель глибокого навчання може ефективно використовуватися для швидкого та автоматизованого визначення стану серця пацієнта. Автоматична сегментація дозволяє точно визначити контури міокарда, що має важливе значення для діагностики серцевих захворювань та оцінки їхнього ступеня тяжкості. Застосування цієї моделі також сприяє підтримці медичного персоналу, спрощуючи їхню роботу та забезпечуючи швидку та об'єктивну інформацію щодо структури серця.

**10. Висновок про можливість допуску кваліфікаційної роботи до захисту, на яку оцінку заслуговує робота**

Враховуючи високу якість виконання та відповідність всім необхідним вимогам, робота може бути рекомендована для захисту. Оцінка, яку рекомендується - «добре».

Керівник



д.т.н., професор каф. КН Едуард МАНЗЮК