

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
імені ІГОРЯ СІКОРСЬКОГО»

ФАКУЛЬТЕТ БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ

(повна назва інституту/факультету)

кафедра БІОМЕДИЧНОЇ КІБЕРНЕТИКИ

(повна назва кафедри)

«До захисту допущено»

В.о.завідувачки кафедри БМК

Світлана АЛХІМОВА

(підпис)

(ініціали, ПРІЗВИЩЕ)

“__” __червня__ 2025р.

Дипломна робота

на здобуття ступеня бакалавра

за освітньо-професійною програмою

«Комп'ютерні технології в біології та медицині»

зі спеціальності 122 «Комп'ютерні науки»

на тему:

Зображень

Методи аугментації перфузійних магнітно-резонансних

Виконав: студент IV курсу, групи БС-12

КОВАЛЬЧУК ОЛЕКСІЙ ВІКТОРОВИЧ

(прізвище, ім'я, по батькові)

(підпис)

Науковий керівник: асистент каф. біомедичної кібернетики

Дюмін Олексій Дмитрович

(посада, науковий ступінь, вчене звання, прізвище, ім'я, по ініціали)

(підпис)

Консультант з розділів дипломної роботи:

(назва розділу) (посада, вчене звання, науковий ступінь, прізвище, ініціали)

(підпис)

Рецензент: доцент кафедри біомедичної інженерії, доцент к.п.н

Богданова Тетяна Леонідівна

(посада, науковий ступінь, вчене звання, науковий ступінь, прізвище та ініціали)

(підпис)

Засвідчую, що у цій дипломній роботі
немає запозичень з праць інших авторів
без відповідних посилань.

Студент _____

(підпис)

Київ – 2025 року

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
 Інститут (факультет) БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ

(повна назва)

Кафедра БІОМЕДИЧНОЇ КІБЕРНЕТИКИ

(повна назва)

Рівень вищої освіти – перший (бакалаврський)

Спеціальність 122 «Комп'ютерні науки»

Освітньо-професійна програма «Комп'ютерні технології в біології та медицині»

(код і назва)

ЗАТВЕРДЖУЮ

В.о.завідувачки кафедри БМК

Світлана АЛХІМОВА

« » квітень 2025 р.

ЗАВДАННЯ

на дипломну роботу студенту

КОВАЛЬЧУК ОЛЕКСІЙ ВІКТОРОВИЧ

(прізвище, ім'я, по батькові)

1. Тема роботи Методи аугментації перфузійних магнітно-резонансних зображень

керівник роботи

Дюмін Олексій Дмитрович

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом по університету від «26» травня 2025 р. №1758-с

2. Термін подання студентом роботи

22-23 травня 2025 року

3. Вихідні дані методи аугментації

4. Зміст роботи *Реалізація методів аугментації перфузійних МРТ-зображень мозку для підвищення точності сегментації. Робота виконана мовою Python у середовищі Google Colab. Досліджено геометричні, інтенсивнісні та комбіновані методи, проведено оцінку їх ефективності за допомогою кількісних показників.*

5. Перелік ілюстративного матеріалу (із зазначенням плакатів, презентацій тощо) *13 слайдів (презентація захисту дипломної роботи)*

6. Консультанти розділів роботи^{1*}

^{1*} Якщо визначені консультанти. Консультантом не може бути зазначено наукового керівника магістерської дисертації.

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Дипломної роботи			

7. Дата видачі завдання **06 квітня 2025р.**

Календарний план

№ з/п	Назва етапів виконання дипломної роботи	Термін виконання етапів роботи	Примітка
1	Отримати завдання за темою ДР на практику	До 24.12.2024р.	виконано
2	Переддипломна практика. Виконання практичної частини ДР та додаткових розділів	1-4 тиждень за графіком практики	виконано
3	Виконання основних розділів ДР (Вступ, Огляд літератури, Постановка задачі та вибір методів аугментації, Програмна реалізація методів аугментації та оцінка результатів)	Протягом усієї практики	
4	Перевірка ДР науковим керівником	до 20.05.2025	
5	Подання в електронному вигляді ДР на перевірку нормоконтролера та плагіат (StrikePlagiarism.com). Доопрацювання ДР	Не пізніше 23.05.2025	
6	Отримати відгук від керівника ДР	Не пізніше 05.06.2025	
7	Надати пакету документів по ДР та супровідних до неї документів на засідання кафедри		
8	Подання ДР рецензенту. Отримання рецензії.	09.06 – 13.06.2025	
9	Захист ДР в ЕК	16.06 - 21.06.2025	

Студент

(підпис)

Олексій КОВАЛЬЧУК

(ім'я, ПРІЗВИЩЕ)

Керівник ДР

(підпис)

Олексій ДЮМІН

(ім'я, ПРІЗВИЩЕ)

Нормоконтролер

(підпис)

Галина КОРНІЄНКО

(ім'я, ПРІЗВИЩЕ)

АНОТАЦІЯ

Дипломна робота за темою «Методи аугментації перфузійних зображень магнітно-резонансної томографії» виконана студентом кафедри біомедичної кібернетики ФБМІ Ковальчуком Олексієм Вікторовичем зі спеціальності 122 «Комп'ютерні науки» за освітньо-професійною програмою «Комп'ютерні технології в біології та медицині» та складається зі: вступу; 3 розділів (Огляд літератури, Постановка задачі та вибір методів аугментації, Програмна реалізація методів аугментації та оцінка результатів), висновків до кожного з цих розділів; загальних висновків; списку використаних джерел, який налічує 25 джерела та додатків. Загальний обсяг роботи 63 сторінок.

Актуальність теми. Перфузійна магнітно-резонансна томографія (МРТ) є одним із найважливіших методів функціональної діагностики, який дозволяє оцінити стан мікроциркуляції у тканинах мозку. Проте обмежена кількість якісних розмічених медичних зображень ускладнює ефективне навчання моделей глибокого навчання. Застосування методів аугментації дозволяє розширити доступні датасети, підвищити різноманітність тренувальних прикладів та покращити якість автоматизованої сегментації. Це робить дослідження методів аугментації перфузійних зображень надзвичайно актуальним у контексті розвитку інтелектуальних медичних систем.

Мета і завдання роботи.

Метою роботи є підвищення точності автоматизованої сегментації перфузійних МРТ-зображень мозку шляхом застосування методів аугментації з використанням інструментів машинного навчання.

Її досягнення передбачає вирішення наступних завдань:

1. Аналіз вітчизняних та зарубіжних джерел.
2. Провести аналіз існуючих методів аугментації зображень у медичній візуалізації.
3. Вибрати та реалізувати найбільш релевантні методи аугментації для перфузійних МРТ.

4. Інтегрувати методи аугментації в процес навчання нейронної мережі для підвищення якості сегментації перфузійних МРТ-зображень.

5. Провести порівняльну оцінку ефективності методів за допомогою кількісних метрик сегментації.

6. Надати рекомендації щодо доцільності застосування окремих або комбінованих методів у клінічних системах.

Використані методи. У роботі використано методи аугментації зображень, зокрема геометричні трансформації (обертання, віддзеркалення), інтенсивнісні перетворення (гаусівський шум, CLaNE, зсув інтенсивності), а також їх комбінації. Реалізацію проведено з використанням мови програмування Python та бібліотек OpenCV, NumPy, TensorFlow. Для оцінки ефективності застосовано кількісні метрики якості сегментації: Dice-коефіцієнт, Sensitivity, Specificity, Accuracy.

Отримані результати. В результаті виконання роботи реалізовано програмний модуль для аугментації перфузійних МРТ-зображень мозку, протестовано окремі та комбіновані методи обробки. Найвищу точність сегментації продемонструвала комбінація методів: обертання, віддзеркалення, гаусівський шум, CLaNE і зсув інтенсивності. Аугментація суттєво підвищила точність моделі у порівнянні з неаугментованим набором даних.

Апробація результатів роботи. За результатами виконаної роботи публікацій не планується

Ключові слова аугментація зображень, нейронна мережа, МРТ-зображення, метрики точності сегментації

Бібліографічний опис ДР

Ковальчук О. В. Методи аугментації перфузійних зображень магнітно-резонансної томографії : дипломна роб. бакалавра : 122 Комп'ютерні науки / Сидоренко Василь Петрович. – Київ, 2025. – 63 с

ANNOTATION

The thesis on the topic "Methods of augmentation of perfusion images of magnetic resonance tomography" was completed by a student of the Department of Biomedical Cybernetics of the Federal Institute of Medical Sciences Kovalchuk Oleksiy Viktorovych, major 122 "Computer Science" under the educational and professional program "Computer Technologies in Biology and Medicine" and consists of: an introduction; 3 sections (Literature Review, Problem Statement and Selection of Augmentation Methods, Software Implementation of Augmentation Methods and Evaluation of Results), conclusions for each of these sections; general conclusions; a list of sources used, which includes 25 sources, and appendices. The total volume of the work is 63 pages.

Relevance of the topic. Perfusion magnetic resonance imaging (MRI) is one of the most important methods of functional diagnostics, allowing the assessment of microcirculation in brain tissues. However, the limited number of high-quality annotated medical images complicates the effective training of deep learning models. Image augmentation methods help to expand available datasets, increase training diversity, and improve the quality of automated segmentation. Therefore, research into augmentation methods for perfusion images is highly relevant in the context of developing intelligent medical systems.

Objective and tasks of the work. The aim of the work is to improve the accuracy of automated segmentation of perfusion brain MRI images through the use of augmentation methods with machine learning tools.

To achieve this goal, the following tasks were set:

1. Analyze domestic and international sources.
2. Review existing image augmentation methods in medical imaging.
3. Select and implement the most relevant augmentation methods for perfusion MRI.
4. Integrate data augmentation methods into the training process of the neural network to improve the segmentation quality of perfusion MRI images.

Perform a comparative evaluation of method effectiveness using quantitative segmentation metrics.

5. Provide recommendations for the application of individual or combined methods in clinical systems.

Methods Used. The study employed various image augmentation techniques, including geometric transformations (rotation, flipping), intensity-based modifications (Gaussian noise, CLAHE, intensity shift), as well as their combinations. The implementation was carried out using the Python programming language and the libraries OpenCV, NumPy, and TensorFlow. To evaluate the effectiveness of the applied methods, quantitative segmentation quality metrics were used: Dice coefficient, Sensitivity, Specificity, and Accuracy.

Results obtained. A software module for perfusion brain MRI augmentation was developed. Individual and combined methods were tested. The highest segmentation accuracy was achieved using a combination of rotation, flipping, Gaussian noise, CLAHE, and intensity shift. Augmentation significantly improved model performance compared to the non-augmented dataset.

Approval of results. No publications are planned based on the results of this work.

Keywords image augmentation, neural network, MRI images, segmentation accuracy metrics

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ	10
ВСТУП.....	11
РОЗДІЛ 1 ОГЛЯД ЛІТЕРАТУРИ.....	13
1.1 Основи перфузійної магнітно-резонансної томографії.....	13
1.2 Використання аугментації зображень у МРТ	15
1.3 Особливості аугментації перфузійних МРТ-зображень.....	18
1.4 Класифікація методів аугментації медичних зображень	20
1.4.1 Геометричні методи	21
1.4.2 Інтенсивнісні методи.....	23
1.4.3 Генеративні методи	25
1.4.4 Специфічні методи для медичних зображень.....	26
1.5 Перспективи розвитку аугментації в медичній візуалізації.....	28
Висновки до розділу 1.....	30
РОЗДІЛ 2 ПОСТАНОВКА ЗАДАЧІ ТА ВИБІР МЕТОДІВ АУГМЕНТАЦІЇ.....	31
2.1 Постановка задачі.....	31
2.2 Обґрунтування вибору інструментів розробки.....	32
2.3 Обрані методи аугментації.....	34
2.3.1 Обертання зображення.....	35
2.3.2 Горизонтальне відзеркалення	37
2.3.3 Додавання гаусівського шуму	38
2.3.4 CLANE (локальне вирівнювання гістограми).....	39
2.3.5 Зсув інтенсивності.....	41
2.4 Комбінування методів аугментації.....	42
Висновки до розділу 2.....	43
РОЗДІЛ 3 ПРОГРАМНА РЕАЛІЗАЦІЯ МЕТОДІВ АУГМЕНТАЦІЇ ТА ОЦІНКА РЕЗУЛЬТАТІВ	45
3.1 Реалізація методів аугментації	47
3.2 Комбінації методів аугментації та їх доцільність.....	50

3.3 Оцінка ефективності методів аугментації.....	51
3.3.1 DICE-коефіцієнт	51
3.3.2 Чутливість.....	52
3.3.3 Специфічність.....	52
3.3.4 Точність.....	53
3.4. Аналіз результатів застосування методів аугментацій.....	53
3.5 Захист інформації	56
3.6 Розрахунок економічного ефекту	56
Висновки до 3 розділу.....	58
ЗАГАЛЬНІ ВИСНОВКИ	59
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	61

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

БД - база даних, це структурована колекція даних, яка зберігається та управляється комп'ютерною системою.

MPT – магнітно-резонансна томографія

ОЗ – об'єм зображення

ШІ – штучний інтелект (українське скорочення)

GAN – генеративно-змагальна мережа

U-Net – згорткова нейронна мережа для сегментації

Dice – коефіцієнт Дайса

SENS – чутливість

SPEC – специфічність

ACCU – точність

CLANE – обмежене адаптивне вирівнювання гістограми.

ВСТУП

Перфузійна магнітно-резонансна томографія (МРТ) є одним із найсучасніших та найбільш інформативних методів нейровізуалізації, який дозволяє неінвазивно оцінити кровообіг у тканинах головного мозку, серця та інших життєво важливих органів. Завдяки високій чутливості до змін у мікроциркуляції, перфузійна МРТ набула широкого застосування в діагностиці таких патологій, як ішемічний інсульт, пухлини, дегенеративні зміни, а також у моніторингу ефективності лікування.

Однак отримання якісних перфузійних зображень пов'язане з низкою технічних складностей. Серед них — артефакти руху пацієнта, наявність шумів, варіативність параметрів сканування та обмеження роздільної здатності апаратури. Ці фактори можуть суттєво впливати на точність подальшої комп'ютерної обробки даних, зокрема на сегментацію патологічних ділянок.

Через високу вартість досліджень і обмежений доступ до великих обсягів анонімізованих клінічних даних, актуальним є використання **методів аугментації** зображень — штучного розширення навчальної вибірки для моделей машинного навчання. Аугментація підвищує узагальнюючу здатність нейронної мережі без необхідності в нових розмічених даних, що особливо важливо в медицині.

Мета і завдання роботи

Метою роботи є підвищення точності автоматизованої сегментації перфузійних МРТ-зображень мозку шляхом застосування методів аугментації з використанням інструментів машинного навчання.

Її досягнення передбачає вирішення наступних *завдань*:

1. Аналіз вітчизняних та зарубіжних джерел.
2. Провести аналіз існуючих методів аугментації зображень у медичній візуалізації.
3. Вибрати та реалізувати найбільш релевантні методи аугментації для перфузійних МРТ.
4. Інтегрувати методи аугментації в процес навчання нейронної мережі для

підвищення якості сегментації перфузійних МРТ-зображень.

5. Провести порівняльну оцінку ефективності методів за допомогою кількісних метрик сегментації.

6. Надати рекомендації щодо доцільності застосування окремих або комбінованих методів у клінічних системах.

Використані методи У роботі використано методи аугментації зображень, зокрема геометричні трансформації (обертання, віддзеркалення), інтенсивнісні перетворення (гаусівський шум, CLAHE, зсув інтенсивності), а також їх комбінації. Реалізацію проведено з використанням мови програмування Python та бібліотек OpenCV, NumPy, TensorFlow. Для оцінки ефективності застосовано кількісні метрики якості сегментації: Dice-коефіцієнт, Sensitivity, Specificity, Accuracy.

Отримані результати. В результаті виконання роботи реалізовано програмний модуль для аугментації перфузійних МРТ-зображень мозку, протестовано окремі та комбіновані методи обробки. Найвищу точність сегментації продемонструвала комбінація методів: обертання, віддзеркалення, гаусівський шум, CLAHE і зсув інтенсивності. Аугментація суттєво підвищила точність моделі у порівнянні з неаугментованим набором даних.

Публікації. Не заплановано

Структура роботи

Дипломна робота за темою «Методи аугментації перфузійних магнітно-резонансних зображень» виконана студентом Ковальчуком Олексієм Вікторовичем 122 «Комп'ютерні науки» за освітньо-професійною програмою «Комп'ютерні технології в біології та медицині», побудована за класичним типом та викладена на 63 сторінках машинописного тексту. Вона складається з: вступу; 3 розділів (*перерахувати розділи згідно змісту*), висновків до кожного з цих розділів; загальних висновків; списку використаних джерел, який налічує 25 джерел та додатків (2 – на кирилиці, 23 – на латиниці). В роботі представлено 8 рисунків і 1 таблиці

РОЗДІЛ 1

ОГЛЯД ЛІТЕРАТУРИ

1.1 Основи перфузійної магнітно-резонансної томографії

Перфузійна МРТ є одним із провідних методів функціональної візуалізації в медицині, який дозволяє оцінити стан кровопостачання тканин у режимі реального часу. На відміну від класичної структурної МРТ, орієнтованої переважно на анатомічні особливості органів і тканин, перфузійна МРТ фокусується на фізіологічних процесах мікроциркуляції, які забезпечують життєдіяльність клітин і органів [2]. Саме ця властивість робить метод незамінним у клінічній практиці для виявлення патологічних станів, ранньої діагностики ішемічних порушень та оцінки ефективності терапевтичних заходів.

Фізичний принцип роботи перфузійної МРТ ґрунтується на реєстрації змін магнітних властивостей тканин, які відбуваються внаслідок руху крові через капілярне русло. Для підвищення контрастності дослідження часто використовуються парамагнітні контрастні агенти на основі гадолінію, які тимчасово змінюють локальні магнітні поля і відповідно впливають на сигнал МРТ-сканування. Завдяки цьому стає можливим побудова високоточних карт перфузії тканин. У той же час для пацієнтів із ризиком нефрогенного системного фіброзу або іншими протипоказаннями до контрасту були розроблені безконтрастні методики, зокрема артеріальне спін-маркування (ASL), яке передбачає магнітне мічення протонів води в артеріальній крові без застосування сторонніх агентів [1]. ASL відкриває нові можливості безпечного багаторазового обстеження у динаміці без шкоди для здоров'я пацієнта.

У клінічній практиці найбільш поширеними техніками перфузійної МРТ є динамічна контрастно-болюсна МРТ (DSC-MRI), динамічна контрастно-посилена МРТ (DCE-MRI) та артеріальне спінове міткування (ASL). DSC-MPT базується на оцінці змін сигналу, що відбуваються після введення болюсу контрастної

речовини, і широко використовується для картування мозкового кровотоку (CBF), об'єму крові в тканині (CBV) та часу транзиту крові (MTT) [2]. Ця техніка вважається «золотим стандартом» у гострій неврології, особливо при діагностиці інсультів, де швидкість прийняття рішень є критично важливою.

DCE-MPT орієнтована на динамічне відстеження накопичення контрастної речовини в тканинах і використовується переважно для аналізу судинної проникності та оцінки пухлинної ангіогенезії. Метод дозволяє будувати кінетичні моделі обміну речовини між судинним руслом і міжклітинним простором, що є надзвичайно цінним при плануванні онкологічного лікування та оцінці ефективності хіміотерапії [2].

Метод артеріального спінового міткування, хоча й технічно складніший у реалізації, набирає популярності завдяки своїй неінвазивності та відсутності необхідності у контрастуванні. ASL дозволяє кількісно оцінювати мозковий кровотік у абсолютних одиницях (мл/100 г тканини/хв), що є вагомою перевагою для досліджень у хронічних судинних патологіях або при моніторингу терапевтичних втручань у нейродегенеративних захворюваннях.

Основними параметрами перфузії, які визначаються за допомогою цих технік, є швидкість мозкового кровотоку (CBF), об'єм крові в тканині (CBV), середній час транзиту крові (MTT) та час досягнення піку контрастності (TTP). Кількісна оцінка цих показників є надзвичайно важливою для диференціації життєздатних та незворотно пошкоджених тканин. Наприклад, збільшення середнього часу транзиту та зниження швидкості кровотоку є типовими ознаками ішемічної пенумбри — зони мозкової тканини, що знаходиться у ризику, але ще може бути врятована за умови своєчасного лікування [3].

Клінічне застосування перфузійної MPT охоплює широкий спектр напрямів медицини. У неврології метод є незамінним для діагностики гострого ішемічного інсульту, хронічної ішемії мозку, судинної деменції та нейродегенеративних розладів. В онкології перфузійна MPT допомагає диференціювати пухлинні процеси від посттерапевтичних змін тканини, визначати ступінь злоякісності пухлин та моніторити відповідь на лікування. У кардіології застосування

перфузійної МРТ міокарда дозволяє виявляти ішемічні ураження навіть на ранніх стадіях, що має критичне значення для прогнозу та вибору лікувальної тактики. У нефрології метод використовується для оцінки перфузії нирок, що важливо при діагностиці гострої ниркової недостатності та васкулітів.

Окрім традиційного клінічного застосування, перфузійна МРТ знаходить нові ніші у дослідженнях механізмів старіння, моніторингу ефективності судинних терапій та вивченні впливу різних захворювань на мікроциркуляцію в органах. Зокрема, сучасні дослідження фокусуються на інтеграції даних перфузії з метаболічними та структурними характеристиками, що дозволяє створювати більш комплексні моделі патологічних процесів.

В останні роки значна увага приділяється розвитку автоматизованих систем обробки перфузійних даних. Використання методів машинного навчання для автоматичної побудови перфузійних карт, виділення зон інтересу та кількісного аналізу покликане значно підвищити точність і швидкість діагностики [4]. Це дозволяє не лише стандартизувати результати досліджень між різними клініками, але й мінімізувати вплив людського чинника на процес інтерпретації складних зображень.

Таким чином, перфузійна магнітно-резонансна томографія є надзвичайно потужним і гнучким інструментом сучасної діагностики. Її переваги — висока інформативність, неінвазивність і здатність забезпечувати кількісну оцінку фізіологічних процесів — роблять її незамінною в багатьох галузях медицини. Подальший розвиток технологій сканування, математичного моделювання та автоматизованої обробки даних відкриває нові перспективи для розширення можливостей застосування перфузійної МРТ у клінічній практиці та наукових дослідженнях.

1.2 Використання аугментації зображень у МРТ

Саме в цьому контексті методи аугментації зображень відіграють критичну роль у підготовці даних для навчання. Вони дозволяють штучно розширити

доступні вибірки, зберігаючи при цьому клінічну достовірність і структурну цілісність зображень, що особливо важливо у випадку МРТ.

Аугментація зображень є фундаментальним етапом у побудові сучасних систем автоматизованої медичної діагностики. Особливо важливою вона стає у сфері магнітно-резонансної томографії (МРТ), де якість і обсяг навчальних даних безпосередньо впливають на точність і стійкість алгоритмів машинного навчання [5]. Перфузійна МРТ, як специфічний різновид МР-досліджень, висуває додаткові вимоги до процесу аугментації через свою кількісну природу та високу чутливість до змін у структурі даних.

Основною метою аугментації є розширення обсягу даних без необхідності проведення додаткових досліджень на пацієнтах. Це дозволяє значно зменшити фінансові витрати, прискорити процес збору даних і, найголовніше, уникнути етичних ризиків, пов'язаних із надмірним навантаженням на пацієнтів. При цьому створюються нові варіації зображень шляхом застосування різноманітних перетворень, що імітують можливі відмінності, які можуть виникнути в реальних клінічних умовах.

У загальній практиці для аугментації медичних зображень використовуються стандартні методи, такі як обертання, масштабування, зміщення, дзеркальне відображення, зміна яскравості та контрастності. У контексті перфузійної МРТ їх застосування має бути вкрай обережним. Будь-яка невдала трансформація може призвести до спотворення кількісної інформації, що є критично важливим для діагностики, прогнозування та планування лікування [6].

При аугментації перфузійних карт допустимі лише мінімальні просторові трансформації: невеликі повороти до 10–15 градусів, масштабування в межах 5–10 %, обережні зсуви з подальшою корекцією просторових координат. Будь-які зміни яскравості чи контрастності мають проводитись виключно в межах фізіологічно обґрунтованих допустимих варіацій, аби не змінити співвідношення кровотоку та об'єму крові у тканинах. Для контролю таких трансформацій усе частіше застосовуються математичні моделі фізіології кровообігу, що дає змогу забезпечити клінічну валідність результатів.

Особливо важливо, що перфузійна МРТ орієнтується не лише на візуальну оцінку зображення, але й на чисельний аналіз параметрів, таких як швидкість мозкового кровотоку (CBF), об'єм крові в тканинах (CBV), середній час транзиту (MTT) та час досягнення піку контрасту (TTP). Отже, навіть незначні артефакти або зміни у структурі даних можуть призвести до серйозних клінічних помилок.

Застосування генеративних підходів, зокрема генеративно-змагальних мереж (GANs), відкрило нові можливості у сфері аугментації перфузійних МРТ-даних. GAN-моделі здатні створювати реалістичні синтетичні зображення, що відображають як нормальні фізіологічні стани, так і патології різного ступеня тяжкості [7]. Це дозволяє суттєво розширити навчальні вибірки, особливо у випадках, коли реальні клінічні дані є обмеженими або коли потрібно збалансувати класи для задач сегментації або класифікації.

Крім того, генеративні моделі можуть моделювати специфічні клінічні сценарії, наприклад, розвиток ішемії в різних ділянках мозку або етапи росту пухлин, що на практиці значно покращує здатність алгоритмів до виявлення атипових випадків. Це особливо важливо для задач ранньої діагностики, де помилки можуть мати критичні наслідки для пацієнта.

Розвиток дифузійних моделей (diffusion models) ще більше розширив можливості аугментації. Ці моделі демонструють здатність генерувати надзвичайно реалістичні структури, зберігаючи тонкі анатомічні деталі, що особливо важливо для діагностики дрібних судинних патологій, наприклад, мікроінфарктів мозку [8]. Diffusion models працюють за принципом поступового "очищення" випадкового шуму, що дозволяє моделювати дуже складні і природні варіації тканинних структур.

Паралельно активно розвиваються підходи самонавчання (self-supervised learning). У цих стратегіях моделі навчаються на великих обсягах незрозумітих даних без необхідності ручної розмітки. Використання аугментації у процесі самонавчання дозволяє суттєво покращити якість отриманих представлень даних і, відповідно, підвищити ефективність подальшого тонкого навчання моделей для конкретних клінічних задач [6]. Це відкриває великі перспективи для застосування

штучного інтелекту в медицині у масштабах, недосяжних для традиційних підходів.

Завдяки аугментації вдалося значно покращити показники точності у багатьох клінічних задачах, таких як виявлення ранніх ознак інсульту, сегментація пухлин головного мозку, оцінка васкуляризації тканин при онкологічних захворюваннях та діагностика кардіологічних патологій на основі перфузійної МРТ. Більш того, синтетичні дані вже активно використовуються у мультицентрових дослідженнях, де необхідна стандартизація підходів до аналізу даних, отриманих на різному обладнанні і в різних клініках.

Таким чином, аугментація зображень у МРТ, а особливо в перфузійній МРТ, є не просто допоміжним інструментом, а критично важливою складовою процесу розробки високоточних діагностичних систем. Завдяки розвитку новітніх технологій, таких як GANs, diffusion models та self-supervised learning, з'являються нові можливості для покращення якості діагностики, підвищення достовірності висновків та прискорення інтеграції штучного інтелекту в клінічну практику. Проте разом із цими можливостями виникають і нові виклики — забезпечення клінічної достовірності, етичність використання синтетичних даних та відповідність міжнародним стандартам безпеки.

1.3 Особливості аугментації перфузійних МРТ-зображень

Аугментація медичних зображень відіграє важливу роль у розробці сучасних систем машинного навчання, проте у випадку перфузійної магнітно-резонансної томографії (МРТ) існують специфічні особливості, які потребують особливої уваги та дотримання низки принципів. Перфузійні МРТ-зображення відрізняються від традиційних анатомічних сканів тим, що вони містять кількісну інформацію про кровотік, об'єм крові та інші параметри мікроциркуляції тканин. Через це навіть незначні модифікації структури або інтенсивності зображення можуть призводити до суттєвих помилок у клінічній інтерпретації.

На відміну від загальних комп'ютерних зображень, де для аугментації

можуть використовуватися широкі діапазони перетворень, у перфузійній МРТ допустимі лише обмежені зміни. Просторові трансформації, такі як обертання або масштабування, мають виконуватися дуже обережно. Зазвичай допустимими вважаються невеликі повороти до 10–15 градусів та масштабування у межах 5–10 %, що дозволяє уникнути спотворення анатомічних структур і зберегти фізіологічну відповідність даних [5].

Особливо важливим аспектом є збереження кількісних характеристик перфузійних карт, таких як CBF чи CBV. Будь-які зміни яскравості або контрастності мають бути мінімальними та фізіологічно обґрунтованими, оскільки інтенсивність сигналу напряму відображає клінічно значущі фізіологічні процеси [6]. Невдале коригування цих параметрів може призвести до неправильного трактування результатів діагностики, що є критичним ризиком у медичній практиці.

Застосування генеративних методів у аугментації перфузійних МРТ-зображень відкриває нові можливості для розширення тренувальних вибірок без ризику зменшення клінічної достовірності даних. Генеративно-змагальні мережі (GANs) здатні створювати синтетичні зображення, які відтворюють анатомічні та фізіологічні особливості реальних сканів з високою точністю [7]. Це дозволяє моделювати як нормальні, так і патологічні стани, що суттєво покращує здатність моделей машинного навчання до виявлення аномалій у клінічних даних.

Ще одним важливим напрямком є використання дифузійних моделей (diffusion models), які демонструють високу якість синтетичних зображень та здатність зберігати навіть найтонші деталі анатомічної структури [8]. На відміну від GANs, diffusion models працюють шляхом поступового внесення шуму у дані та подальшого відновлення оригінального зображення, що забезпечує вищу стабільність і кращу відповідність реальним фізіологічним особливостям.

Не менш важливою особливістю аугментації перфузійних даних є необхідність збереження топологічної цілісності тканин. У загальних задачах комп'ютерного зору деформації можуть бути корисними для підвищення різноманітності вибірки. Натомість у медицині навіть незначне спотворення

анатомічних структур може призвести до помилкових діагностичних висновків. Тому деформаційні трансформації у перфузійній МРТ застосовуються вкрай обмежено або взагалі не використовуються без додаткової біофізичної валідації.

Водночас, при правильному підході, комбінація слабких трансформацій, таких як невеликі повороти, масштабування та контрольоване додавання шуму, може суттєво покращити здатність моделей розпізнавати варіації даних, що виникають у клінічній практиці через різні параметри сканування або індивідуальні анатомічні особливості пацієнтів.

Окрему роль відіграє також застосування self-supervised learning у контексті аугментації. Методики самонавчання дозволяють використовувати великі обсяги незрозумітих перфузійних зображень, навчаючи моделі виявляти приховані залежності без потреби в дорогій ручній розмітці [6]. Це особливо актуально в умовах обмеженої доступності даних та потреби у швидкому розширенні тренувальних наборів.

Таким чином, особливості аугментації перфузійних МРТ-зображень зумовлені високою клінічною значущістю представленої інформації. Успішна реалізація аугментаційних підходів вимагає поєднання знань у сфері фізіології кровообігу, принципів магнітно-резонансної візуалізації та сучасних технологій штучного інтелекту. Правильна побудова процесу аугментації забезпечує не лише покращення якості тренування моделей, але й підвищення їхньої клінічної надійності та точності діагностичних висновків.

1.4 Класифікація методів аугментації медичних зображень

Аугментація медичних зображень охоплює сукупність методів, які дозволяють штучно розширити обсяг тренувальних даних, зберігаючи при цьому клінічну достовірність. Класифікація методів за типом їх впливу на зображення дозволяє ефективніше обирати стратегії трансформації залежно від задачі: сегментації, класифікації або детекції патологій.

Геометричні методи змінюють просторове положення зображення без впливу

на його інтенсивні характеристики. Найчастіше використовуються обертання (до $\pm 15^\circ$), горизонтальне віддзеркалення, масштабування та зсув. Такі трансформації дозволяють моделювати варіації, що виникають при різних положеннях пацієнта під час сканування, однак потребують обережності для збереження анатомічної відповідності [7].

Інтенсивнісні методи змінюють розподіл яскравості пікселів, імітуючи відмінності, що можуть виникати через налаштування обладнання або фізіологічні варіації. Найпоширеніші з них — додавання гаусівського шуму, зміна контрастності та яскравості, а також гамма-корекція. Ці методи дозволяють зробити модель стійкішою до змін, не впливаючи на топологію зображення [23].

Генеративні методи, як-от генеративно-змагальні мережі (GAN) і дифузійні моделі (Diffusion Models), дають змогу створювати синтетичні зображення, які точно імітують клінічні патерни. Вони є особливо ефективними при роботі з невеликими вибірками або рідкісними патологіями. Наприклад, GAN дозволяють моделювати різні стадії розвитку ішемії або пухлин [6].

Специфічні медичні підходи включають patch-based аугментацію, domain adaptation та self-supervised learning. Ці методи враховують тривимірну природу даних, а також дозволяють адаптувати моделі до нових джерел без потреби в ручній розмітці.

Правильний вибір типу аугментації є критичним для медичних задач, де навіть незначні зміни у структурі або інтенсивності можуть вплинути на діагностичні висновки. Комбіноване використання трансформацій забезпечує баланс між збільшенням обсягу даних і збереженням клінічної точності.

1.4.1 Геометричні методи

Геометричні методи є найпростішими й водночас найбільш широко застосовуваними у практиці аугментації медичних зображень. Вони змінюють просторові параметри зображення — положення, орієнтацію, масштаб — не порушуючи при цьому базової структури та інтенсивності пікселів, що особливо важливо у клінічному контексті. Основна перевага цих методів полягає у тому, що вони дозволяють моделювати природну варіативність у положенні пацієнта або

розташуванні органів без створення фальсифікованих патологій.

Одним із ключових геометричних перетворень є обертання (rotation). У задачах медичної візуалізації його зазвичай обмежують до кута в межах $\pm 10\text{--}15^\circ$, аби уникнути викривлень анатомічних структур [16]. Наприклад, при аналізі перфузійної МРТ головного мозку навіть невелике обертання дозволяє моделі навчитися розпізнавати однакові патології при різних положеннях голови пацієнта. На рисунку 1 показано, як виглядає зображення МРТ після обертання на 15° .

Дзеркальне відображення (flipping) — горизонтальне або вертикальне — є ефективним методом для симетричних структур, таких як мозок або легені. Наприклад, горизонтальний віддзеркалення дозволяє збільшити обсяг тренувальних даних у 2 рази без втрати значущої анатомічної інформації [18]. Проте його застосування при латералізованих патологіях (наприклад, інсультах) потребує обережності, щоб не спричинити неправильну інтерпретацію локалізації патологічного процесу.

Масштабування (scaling) моделює зміни розмірів органів або зміну поля огляду сканера. У клінічній практиці масштабування застосовують у межах 90–110% від початкового розміру зображення, щоб уникнути порушення пропорцій [24]. Це дозволяє навчити модель бути нечутливою до відмінностей між пристроями. Ефект масштабування зображення також продемонстровано на рисунку 1.

Переміщення (translation) — ще один базовий метод, який зміщує зображення по горизонталі або вертикалі. Це дає змогу моделювати зміну позиції пацієнта або неточності при обрізанні знімків. Рекомендується обмежити зміщення в межах 5–10% [24], аби уникнути втрати важливої інформації в зонах краю (приклад показано на рис. 1.1).




Рисунок 1.1 – Геометричні методи

Деякі дослідники також розглядають еластичні деформації як геометричні трансформації, однак вони майже не застосовуються у задачах, де критичним є збереження анатомічної достовірності. За відсутності спеціальної біомеханічної моделі деформації можуть ввести суттєві похибки [5].

Таким чином, геометричні трансформації є основою більшості аугментаційних підходів, однак у медичних задачах вони потребують особливо обережного застосування. Вибір допустимих меж трансформацій має базуватися на клінічних критеріях і фізіологічній обґрунтованості змін.

1.4.2 Інтенсивнісні методи

Інтенсивнісні методи аугментації змінюють числові параметри пікселів зображення без втручання в його геометричну структуру. Це дозволяє імітувати природні варіації умов сканування, особливості апаратного забезпечення або фізіологічні зміни тканин, зберігаючи при цьому цілісність анатомічної інформації. Такі трансформації підвищують узагальнювальну здатність моделей, навчаючи їх стійкості до варіацій інтенсивності, які не мають діагностичного значення.

Зміна яскравості (brightness adjustment) моделює вплив освітлення або варіацій сигналу, які можуть виникати при використанні різних томографів або параметрів сканування. Коригування яскравості в межах $\pm 30\%$ є ефективним способом зробити модель стійкішою до недоекспонованих або пересвітлених зображень [4].

Зміна контрастності (contrast adjustment) допомагає посилити розділення між структурами, які мають подібні рівні яскравості. Це особливо корисно при

візуалізації м'якотканинних структур, пухлин або ішемічних вогнищ, які можуть бути слабо вираженими на оригінальному зображенні [7].

Додавання гаусівського шуму (Gaussian noise) імітує низьку якість зображення, що може бути спричинена рухом пацієнта, низьким сигналом або особливостями апаратури. Це тренує модель бути стійкою до реалістичних артефактів і дозволяє покращити результати в умовах, наближених до клінічних

Гамма-корекція (gamma correction) є нелінійною трансформацією, яка підсилює або приглушує інтенсивність світлих і темних ділянок. Це дозволяє адаптувати зображення до різних умов освітлення, покращити візуальне сприйняття та водночас зберегти кількісну точність [22].

Додатково до класичних методів, у медичній візуалізації застосовуються також методи нормалізації та вирівнювання інтенсивності, які мають важливе значення при обробці великої кількості зображень з різних джерел:

Нормалізація інтенсивності — це приведення діапазону піксельних значень до уніфікованої шкали (наприклад, $[0, 1]$ або $[-1, 1]$), що дозволяє усунути варіації, зумовлені відмінностями у сканерах або налаштуваннях. Це критично важливо для підтримання узгодженості між різними серіями даних [4].

Histogram equalization (глобальне вирівнювання гістограми) — метод, що перерозподіляє піксельні значення для досягнення більш рівномірного розподілу яскравості. Це покращує контраст зображення, роблячи менш помітні деталі більш вираженими, зокрема в темних або насичених ділянках [22].

CLAHE (Contrast Limited Adaptive Histogram Equalization) — локалізована адаптивна версія вирівнювання гістограми, яка обмежує посилення шуму. Вона працює на мікрорівні блоків зображення, зберігаючи локальні структури і підвищуючи контрастність у складних ділянках (наприклад, при візуалізації дрібних судин або мікроінфарктів).

Ще одним простим, але ефективним інтенсивнісним методом є зсув інтенсивності (intensity shift). Він полягає у додаванні до кожного пікселя зображення сталої або випадкової величини в межах допустимого діапазону (наприклад, ± 30 одиниць яскравості). Такий метод дозволяє моделювати зміни

сигналу, спричинені відмінностями між апаратурою, варіативністю протоколів сканування або фізіологічними факторами пацієнта. Завдяки своїй простоті та стабільності, зсув інтенсивності часто використовується як базова трансформація у задачах класифікації та сегментації, підвищуючи узагальнюючу здатність моделі.

Результати всіх методів інтенсивності можна побачити на рис. 1.2.




Рисунок 1.2 – Інтенсивнісні методи

Важливо, що інтенсивнісні методи часто комбінуються між собою або з геометричними трансформаціями, що дозволяє створити багатий і реалістичний набір навчальних прикладів без втрати клінічної релевантності. Їх застосування має бути обмеженим і контрольованим, особливо в задачах, де інтенсивність сигналу має кількісне значення (наприклад, у перфузійній МРТ).

1.4.3 Генеративні методи

Генеративні методи аугментації є одним із найінноваційніших підходів у сучасній медичній візуалізації. Вони дозволяють не просто трансформувати наявні зображення, а створювати нові синтетичні приклади, що зберігають клінічну достовірність і реалістичність. Такі підходи є особливо корисними у випадках, коли доступ до розмічених медичних даних обмежений або є значна диспропорція між класами (наприклад, дуже мало патологічних випадків у наборі даних).

Генеративно-змагальні мережі (GANs) — найпоширеніший інструмент цієї категорії. Архітектура GAN складається з двох моделей: генератора, який створює зображення, і дискримінатора, який оцінює їхню правдоподібність. В процесі змагання обидві моделі навчаються покращувати результат, що зрештою дозволяє отримати реалістичні зображення з імітацією анатомічних структур і патологій.

GAN вже показали високу ефективність у задачах сегментації пухлин, симуляції ішемії та генерації зображень різних модальностей (наприклад, синтез КТ на основі МРТ) [5].

Дифузійні моделі (Diffusion Models) — новітній клас генеративних алгоритмів, які імітують зворотній процес дифузії: від випадкового шуму до структури зображення. Їх перевагою є більш стабільне навчання та здатність зберігати найдрібніші деталі анатомії, що особливо важливо в нейровізуалізації. Дифузійні моделі поступово витісняють GANs у задачах, де важлива висока точність локальних змін, наприклад, при створенні зображень мікроінфарктів або капілярних аномалій [11].

Variational Autoencoders (VAEs) — ще один тип генеративних моделей, який базується на імовірнісному кодуванні зображень. VAE менш схильні до артефактів і дозволяють отримати контрольовану варіацію в синтезованих даних. Наприклад, змінюючи латентні параметри, можна створити варіанти однієї й тієї самої патології на різних стадіях розвитку.

Генеративні методи також відкривають нові можливості для реалізації підходів weak- та self-supervised learning: синтетичні зображення можуть бути використані як додаткові приклади для попереднього навчання, а також для балансування незбалансованих вибірок у задачах класифікації та сегментації [5].

Разом з тим, використання генеративних моделей у медичній практиці супроводжується певними викликами:

- необхідність клінічної валідації створених зображень;
- потенційна небезпечність помилкових синтетичних даних у навчанні;
- етичні аспекти використання штучно згенерованих прикладів.

Незважаючи на це, генеративні моделі мають великий потенціал у персоналізованій медицині, розробці цифрових аватарів пацієнтів і створенні симуляційних систем для навчання медичного персоналу.

1.4.4 Специфічні методи для медичних зображень

Окрім загальних аугментаційних технік, у медичній візуалізації використовуються спеціалізовані підходи, які враховують анатомічну специфіку,

тип даних (часто 3D) та обмеження, пов'язані з клінічною достовірністю. Такі методи часто не мають універсального характеру, але є надзвичайно ефективними у вузьких задачах, зокрема в нейровізуалізації, онкології або кардіології.

Patch-based augmentation — один із найбільш вживаних підходів при роботі з об'ємними (3D) даними. Він полягає у розрізанні зображення на менші фрагменти (патчі) з подальшим випадковим вибором, перекриттям або комбінуванням. Це дозволяє зменшити обсяг пам'яті, необхідної для обробки, і водночас збільшити варіативність тренувальних прикладів. Наприклад, при сегментації пухлин у мозку замість повного знімка можна використовувати тільки ті фрагменти, що містять зону інтересу, що дозволяє моделі краще фокусуватися на патологіях [12].

Domain adaptation — метод, який дозволяє навчати модель на одному наборі даних (джерельному домені) і переносити знання на інший (цільовий домен), навіть якщо між ними існують значні відмінності (наприклад, різні клініки, апарати або популяції пацієнтів). Для цього використовуються або симуляції реальних умов (synthetic-to-real transfer), або спеціальні регуляризації, що зменшують відстань між розподілами ознак. У контексті МРТ це дозволяє підвищити адаптивність моделей до різних сканерів без втрати точності [13].

Self-supervised augmentation — аугментація в задачах самонавчання, коли модель навчається на основі власних змінених копій зображення. Наприклад, дві аугментовані версії одного МРТ-знімка (з шумом і поворотом) подаються на вхід двом копіям моделі, яка має навчитись розуміти, що це одне і те саме джерело. Такий підхід дозволяє ефективно використовувати незрозмічені дані, які переважають у медичній практиці [19].

Інші специфічні методи включають:

- Mixup — комбінування двох зображень і міток для покращення узагальнення;
- CutMix — вирізання й вставка ділянок із різних зображень;
- Modality mix — об'єднання різних медичних модальностей (наприклад, МРТ і КТ).

Загалом специфічні методи дозволяють враховувати медичний контекст,

структурні обмеження та кількісні характеристики зображень. Вони є ключовими у завданнях високої точності, таких як автоматизована діагностика, планування хірургії або оцінка прогресії захворювання.

1.5 Перспективи розвитку аугментації в медичній візуалізації

Перспективи застосування аугментації даних у медичній візуалізації виглядають надзвичайно багатообіцяючими. З огляду на стрімкий розвиток технологій штучного інтелекту, новітні методи аугментації вже сьогодні стають невід'ємною складовою сучасних систем діагностики і прогнозування у медицині. Водночас прогнозується подальше розширення їхнього застосування у найближчому майбутньому, що охопить як удосконалення існуючих підходів, так і появу принципово нових технологій [6].

Одним із ключових напрямів розвитку стане глибша інтеграція аугментаційних технік у клінічні процеси. Зокрема, очікується створення гібридних систем, які поєднуюватимуть реальні клінічні дані з синтетичними, отриманими за допомогою генеративних моделей, для підвищення точності та стабільності діагностичних рішень. Особливо актуальним це є для рідкісних захворювань, де брак реальних даних ускладнює тренування моделей глибокого навчання [21]. Створення великих синтетичних вибірок на основі невеликої кількості реальних прикладів дозволить ефективніше вирішувати задачі виявлення нетипових патологій.

Перспективним напрямом є також розвиток умовно-релятивістських моделей генерації даних, де процес аугментації враховує індивідуальні особливості пацієнта, такі як вік, стать, наявність супутніх захворювань або особливості анатомії. Це дозволить створювати персоналізовані навчальні вибірки, що підвищить точність прогнозних моделей і сприятиме розвитку персоналізованої медицини [10]. Зокрема, такі підходи є надзвичайно важливими при дослідженні перфузії мозку у пацієнтів з інсультом, де індивідуальні відмінності мають вирішальне значення для прийняття клінічних рішень.

Очікується подальший розвиток самонавчальних підходів (self-supervised learning), що дозволяють мінімізувати залежність від розмічених вибірок. Використання спеціально розроблених аугментаційних стратегій для самонавчання дозволить значно покращити якість репрезентацій медичних даних, що своєю чергою сприятиме створенню більш універсальних моделей для широкого спектра клінічних завдань [6]. У перспективі це відкриває можливості створення єдиних моделей для діагностики різних захворювань без потреби в їхньому повному перенавчанні для кожної нової задачі.

Важливою тенденцією є розвиток мультицентрових навчальних систем, де моделі тренуються на даних, отриманих з різних медичних установ, що мають свої технічні особливості сканування, протоколи та популяційні характеристики пацієнтів. Аугментація в такому контексті дозволить моделювати різноманітність джерел даних, підвищуючи стійкість і узагальнюючу здатність моделей до варіацій реального світу. Це особливо важливо в умовах глобалізації медицини і переходу до використання телемедичних систем у діагностиці та моніторингу пацієнтів [21].

Окремої уваги заслуговує перспектива розвитку так званої адаптивної аугментації, коли методи трансформації підлаштовуються під характеристики конкретного зображення або клінічного випадку. Такі системи зможуть автоматично визначати оптимальні типи і рівень аугментацій залежно від складності задачі, особливостей скана або бажаної клінічної мети. Адаптивні стратегії аугментації дозволять досягти ще більшої точності діагностичних моделей при одночасному зниженні ризику втрати критичної інформації [10].

Очікується також подальший розвиток технологій валідації синтетичних даних. Створення автоматизованих систем оцінювання якості згенерованих зображень, які використовуватимуть критерії відповідності клінічним стандартам і біомедичним характеристикам, дозволить безпечно інтегрувати синтетичні дані у тренувальні вибірки.

Ще одним важливим напрямом розвитку стане інтеграція аугментації з іншими технологіями штучного інтелекту, зокрема з мультизадачним навчанням (multi-task learning), де одна модель одночасно вирішує кілька взаємопов'язаних

задач. У таких системах правильно організована аугментація сприятиме кращій передачі знань між задачами, підвищуючи загальну ефективність діагностичних систем.

Таким чином, перспективи розвитку аугментації у медичній візуалізації є надзвичайно широкими та різноманітними. Використання новітніх підходів до генерації даних, персоналізації аугментаційних стратегій, підвищення якості валідації синтетичних зображень та інтеграції з іншими технологіями машинного навчання створює потужний фундамент для подальшого вдосконалення автоматизованих систем діагностики та прогнозування. Водночас важливою залишається необхідність забезпечення клінічної достовірності створюваних даних та суворої відповідності етичним стандартам, що гарантуватиме безпечне і ефективне застосування нових технологій у реальній клінічній практиці.

Висновки до розділу 1

У розділі здійснено аналіз теоретичних засад перфузійної магнітно-резонансної томографії (MPT) та методів аугментації зображень у медичній візуалізації. Визначено, що перфузійна MPT є одним із провідних методів оцінки мікроциркуляції, що забезпечує кількісну оцінку параметрів кровотоку. Розглянуто основні техніки, зокрема DSC-MRI, DCE-MRI та ASL, з акцентом на їх переваги та придатність для клінічного застосування.

Окрему увагу приділено методам аугментації, які класифіковано на геометричні, інтенсивнісні, генеративні та специфічні для медичних даних. Показано, що правильно підібрані техніки аугментації дозволяють підвищити якість навчання моделей машинного навчання без втрати клінічної достовірності. Таким чином, поєднання високоякісної візуалізації з ефективними аугментаційними підходами створює основу для покращення точності та надійності систем автоматизованої діагностики.

РОЗДІЛ 2

ПОСТАНОВКА ЗАДАЧІ ТА ВИБІР МЕТОДІВ АУГМЕНТАЦІЇ

2.1 Постановка задачі

У сучасній медичній практиці автоматизований аналіз зображень є одним із ключових напрямів розвитку штучного інтелекту, що має на меті підвищення точності та швидкості діагностики. Особливо актуальним це є у випадку з перфузійною магнітно-резонансною томографією (МРТ), яка забезпечує унікальну кількісну інформацію про стан мікроциркуляції у тканинах мозку. Цей тип зображень широко застосовується при діагностиці інсультів, ішемічних станів, пухлин та інших патологій, де порушення кровотоку має критичне клінічне значення.

Проте ефективне використання методів глибокого навчання для автоматичної обробки перфузійних знімків натрапляє на низку суттєвих викликів. Основні з них — обмежений обсяг якісно розмічених даних, висока чутливість до варіацій апаратного забезпечення та складність підтримання узгодженості зображень, отриманих у різних умовах. Крім того, перфузійні зображення мають складну структурну та кількісну природу, що вимагає особливо обережного підходу до будь-якої трансформації даних.

У зв'язку з цим ключовим інструментом, що дозволяє покращити якість навчання моделей, є аугментація зображень — процес штучного розширення вибірки за рахунок застосування цілеспрямованих перетворень. Застосування таких методів дозволяє імітувати можливі клінічні варіації, підвищити стійкість моделі до шуму, різного положення пацієнта, апаратних розбіжностей та покращити узагальнювальну здатність без додаткових витрат на отримання нових даних.

Метою даного етапу дослідження є розробка, реалізація та експериментальна перевірка ефективності конкретних методів аугментації у задачі сегментації

перфузійних МРТ-знімків. Для досягнення цієї мети були поставлені наступні задачі:

- обґрунтувати вибір трансформацій, які зберігають клінічну валідність перфузійних зображень;
- реалізувати та протестувати геометричні (обертання, віддзеркалення) та негеометричні (гаусівський шум, CLAFE, зсув інтенсивності) методи;
- здійснити комбіновану аугментацію та порівняти результати з використанням одиничних методів;
- оцінити ефективність сегментації з використанням кожної трансформації на основі обраних метрик;
- зробити висновки щодо доцільності впровадження окремих або комбінованих аугментацій у задачах перфузійної МРТ.

Таким чином, робота спрямована на практичне вирішення задачі підвищення якості автоматизованої сегментації медичних зображень у складному клінічному середовищі, з використанням найбільш доцільних та обґрунтованих підходів до аугментації.

2.2 Обґрунтування вибору інструментів розробки

У межах цього дослідження було реалізовано сегментацію перфузійних МРТ-зображень головного мозку з використанням методів аугментації, орієнтованих на клінічно достовірні трансформації. Основними об'єктами аналізу стали тривимірні томографічні зрізи, що мають кількісну інтенсивнісну структуру, тобто кожне піксельне значення несе фізіологічне навантаження, пов'язане зі швидкістю кровотоку чи об'ємом крові в тканинах.

Для реалізації цього проекту було обрано середовище Google Colaboratory, яке надає можливість використовувати всі переваги інтерактивних блокнотів Jupyter. Його сумісність із хмарними сервісами значно полегшує процес управління даними та експериментами. Це рішення дозволяє реалізовувати складні обчислювальні задачі без необхідності локального обладнання високої потужності,

що актуально для дослідницьких задач у навчальних закладах.

Основною причиною вибору Python стала наявність широкого спектра бібліотек, зокрема OpenCV, які активно використовуються для обробки медичних зображень, а також широка підтримка мови серед наукової спільноти. Python дозволяє легко інтегрувати засоби обробки зображень із фреймворками глибокого навчання, забезпечуючи побудову повноцінного програмного пайплайну — від попередньої обробки до аналізу та виведення результатів..

Для моделювання сегментації було обрано TensorFlow — один із найпоширеніших фреймворків для реалізації нейронних мереж у середовищі Python. Його високий рівень абстракції та підтримка глибокої інтеграції з бібліотекою Keras дають змогу швидко створювати, навчати й тестувати як прості, так і складні моделі. TensorFlow підтримує обчислення на GPU, має вбудовану систему автоматичного обчислення градієнтів та численні інструменти для моніторингу процесу навчання. Саме завдяки цим перевагам він був обраний для побудови сегментаційної моделі в межах даної роботи.

Однією з ключових бібліотек, що використовувались у цьому проєкті, була OpenCV. Вона забезпечує широкий набір функцій для обробки зображень, включаючи геометричні та інтенсивнісні трансформації, що дає змогу ефективно реалізовувати методи аугментації, необхідні для підготовки даних у задачах медичної сегментації. фізичних розмірів вокселів, а також дозволяє застосовувати патч-бейз сегментацію.

Для реалізації сегментаційної моделі було використано TensorFlow — сучасний фреймворк для побудови та навчання нейронних мереж. Його популярність у галузі глибокого навчання зумовлена широкими можливостями, зокрема підтримкою обчислень на GPU, системою автоматичного обчислення градієнтів, вбудованими засобами для відстеження процесу навчання та інтеграцією з бібліотекою Keras, що значно спрощує створення моделей. У дипломній роботі TensorFlow використовувався для розробки архітектури сегментаційної нейромережі, а також для організації процесу навчання, валідації та збереження результатів. Вибір саме цієї бібліотеки був зумовлений її сумісністю з

Google Colab, високою продуктивністю та активною підтримкою спільноти розробників. Окрім фреймворків, було використано бібліотеки NumPy для обробки масивів даних, OpenCV для базових трансформацій зображень, а також Matplotlib для візуалізації результатів експериментів. Дані проходили стандартні етапи підготовки — зчитування, нормалізацію до діапазону $[0, 1]$, стандартизацію розміру, перевірку узгодженості між зображенням і маскою, та поділ на навчальну, валідаційну й тестову вибірки у співвідношенні 68:12:20.

Оцінювання якості сегментації здійснювалося на основі метрик точності, таких як коефіцієнт Dice, чутливість (sensitivity), специфічність (specificity) та загальна точність (accuracy). Для навчання моделі як функція втрат застосовувалася SparseCategoricalCrossentropy, що є стандартним вибором для задач багатокласової сегментації з цілочисельною розміткою. Цей підхід дозволяє ефективно оптимізувати модель при наявності одного класу мітки на піксель, забезпечуючи коректне обчислення похибки між прогнозованими й еталонними класами. Усі етапи обробки реалізовані відповідно до стандартів відтворюваних експериментів: із фіксацією seed-значень, записом параметрів навчання та контролем версій.

У контексті генеративних та аугментаційних моделей було враховано останні тенденції. Зокрема, застосування дифузійних моделей, які продемонстрували переваги в генерації високоякісних медичних зображень завдяки поетапному очищенню шуму, зберігаючи при цьому анатомічні деталі [14]. Це відкриває перспективи подальшого розширення проєкту з акцентом на синтетичне доповнення вибірок.

Таким чином, обрана технологічна база на Python з інтеграцією провідних бібліотек для медичних даних забезпечила всі умови для реалізації ефективної системи аугментації, адаптованої до задач перфузійної МРТ, з урахуванням специфіки кількісних медичних зображень та клінічних обмежень.

2.3 Обрані методи аугментації

Аналіз сучасних досліджень, викладений у розділі 1, підтвердив ключову

роль аугментації даних у медичних задачах сегментації, особливо в умовах обмежених вибірок та варіативності вихідних зображень. Було встановлено, що найефективнішими є методи, які поєднують просторові та інтенсивнісні трансформації, зберігаючи при цьому анатомічну достовірність. До обраних методів увійшли:

- Обертання зображення — для моделювання просторових варіацій положення пацієнта в межах клінічно допустимих значень ($\pm 15^\circ$) [25].
- Горизонтальне відзеркалення — як ефективний спосіб збільшення обсягу даних при роботі з симетричними структурами, зокрема мозком [14].
- Додавання гаусівського шуму — для імітації низької якості знімків, спричиненої рухом пацієнта або апаратними обмеженнями [4].
- CLANE (локальне вирівнювання гістограми) — як засіб підвищення локального контрасту і видимості дрібних структур при збереженні анатомічної цілісності [17].
- Зсув інтенсивності — для моделювання міжсканерних або фізіологічних варіацій, що робить модель більш адаптивною до нових джерел даних [18].

Ці методи були вибрані не лише як окремі інструменти аугментації, а й для можливості їх комбінації, що дозволяє створити реалістичні й різноманітні варіанти навчальних прикладів. При реалізації було дотримано принципів мінімального втручання в структуру зображення, щоб уникнути спотворення даних, критичних для медичної діагностики.

2.3.1 Обертання зображення

Метод обертання зображення є класичним геометричним підходом в аугментації, що дозволяє моделювати зміни позиції об'єкта у просторі. У контексті медичних зображень, зокрема МРТ, обертання імітує ситуації, коли положення голови пацієнта під час сканування має незначні відхилення від ідеального центру. Це є поширеним у клінічній практиці, особливо коли МРТ виконується у гострих станах, таких як інсульт, де пацієнт може не зберігати нерухомість.

Реалізоване в цьому дослідженні обертання відбувається в межах $\pm 15^\circ$, що вважається допустимим діапазоном для збереження анатомічної відповідності.

Перевищення цього порогу може призвести до викривлення структур мозку або зміщення зон перфузійного інтересу за межі кадру. Обертання виконується відносно центру зображення, без зміни розміру або інтерполяції, яка могла б внести додаткові артефакти.

Цей метод дозволяє значно підвищити стійкість моделі до реальних варіацій у даних. У перфузійній МРТ, де важливим є точне співвідношення між анатомією та інтенсивністю сигналу, невеликі обертання не порушують кількісну природу даних, але дають змогу моделі тренуватись на структурних варіаціях.

Візуалізація ефекту наведена на рис. 2.1. Ліворуч — оригінальне зображення головного мозку в аксіальній площині, праворуч — результат обертання на 15 градусів. Видно, що всі основні структури зберігаються, а позиція зображення в полі огляду змінена, що імітує природну варіацію.




Рисунок 2.1 – Обертання

Геометричні трансформації, зокрема обертання, є базовим методом покращення узагальнення в задачах сегментації, і можуть бути ефективні навіть при роботі з обмеженими вибірками [25].

Таким чином, включення обертання у стратегію аугментації дозволяє зменшити ризик переобучення моделі, покращити адаптацію до клінічних варіацій

положення пацієнта і підвищити стабільність результатів при застосуванні моделі на нових даних.

2.3.2 Горизонтальне відзеркалення

Горизонтальне відзеркалення (flipping) є ще одним класичним геометричним методом аугментації, який широко застосовується у задачах комп'ютерного зору. Суть методу полягає в інверсії піксельних координат уздовж вертикальної осі, що візуально виглядає як «дзеркальне» відображення зображення. У медичній візуалізації, особливо при роботі з симетричними структурами, такими як головний мозок, даний метод дозволяє значно збільшити варіативність навчального набору без втрати анатомічної цілісності.

У контексті перфузійної МРТ, горизонтальне відзеркалення є особливо корисним, оскільки зображення мозку мають природну ліво-праву симетрію. Більшість основних анатомічних структур мають парні аналоги (лобові, тім'яні долі, півкулі мозку), тому зміна їхнього просторового розташування не викликає втрати клінічного сенсу. Наприклад, гіперперфузія в лівій півкулі після відзеркалення буде змодельована у правій, але це не впливає на здатність моделі розпізнавати патологію як таку. Симетрія є природним інструментом для аугментації нейровізуалізаційних даних, особливо в умовах обмеженого розміченого набору [25].

З іншого боку, необхідно враховувати, що при роботі з латералізованими патологіями (наприклад, односторонні інсульти, асиметричні пухлини) неконтрольоване застосування відзеркалення може призвести до хибної локалізації у висновках моделі. Саме тому горизонтальний відзеркалення був реалізований лише для зображень без чітко латералізованих міток або із симетричними класами.

На рис. 2.2 представлено результат застосування горизонтального відзеркалення до зображення МРТ. Ліворуч — оригінальний томографічний зріз, праворуч — результат після трансформації. Анатомічні структури збережені повністю, а просторове розташування зон інтересу змінено, що імітує клінічно можливі варіації.



Рисунок 2.2 – Горизонтальне відзеркалення

Таким чином, горизонтальне віддзеркалення виступає простим, але ефективним методом збільшення обсягу навчальних прикладів, підвищення стійкості моделі до симетричних змін і розширення адаптивності при роботі з новими пацієнтами. Його застосування в даному дослідженні дозволяє поліпшити узагальнювальні властивості сегментаційної мережі без втрати клінічної достовірності.

2.3.3 Додавання гаусівського шуму

Додавання гаусівського шуму є класичним інтенсивнісним методом аугментації, що дозволяє імітувати реальні умови, в яких формуються медичні зображення. Зображення, отримані за допомогою магнітно-резонансної томографії, можуть містити артефакти, викликані як технічними факторами (наприклад, особливостями апаратури, температурними коливаннями, рівнем сигналу), так і поведінковими — рухом пацієнта, що спричиняє нечіткість або шум у знімках. Імітація таких умов у тренувальних вибірках дозволяє підвищити стійкість моделей до "шумних" даних.

У рамках цього дослідження було реалізовано додавання шуму на основі нормального розподілу з математичним сподіванням 0 і стандартним відхиленням 15, що дозволяє ввести слабе, але помітне спотворення інтенсивності. Це значення

було підібране експериментально, щоб не втратити діагностичну інформативність зображення і водночас змусити модель навчитися ігнорувати випадкові інтенсивнісні флуктуації.

Варто зазначити, що додавання шуму не змінює анатомічну або топологічну структуру зображення, а впливає виключно на рівень інтенсивності пікселів. Це особливо важливо у випадку перфузійної МРТ, де кількісні характеристики, такі як CBF або CBV, залежать від точного значення сигналу.

На рис 2.3 наведено порівняння між оригінальним зображенням та зображенням після додавання шуму. Видно, що загальна структура зберігається, але з'являється характерна зернистість, типова для МРТ-сканів із низьким співвідношенням сигнал/шум. Це дозволяє моделі бути стійкою до такого типу спотворень, не втрачаючи здатності виявляти клінічно значущі структури.



Рисунок 2.3 – Гаусівський шум

Отже, включення гаусівського шуму як етапу аугментації дозволяє не лише підвищити узагальнення моделі, але й адаптувати її до варіацій, зумовлених клінічною практикою, що є критично важливим у задачах автоматизованої медичної діагностики.

2.3.4 CLaNE (локальне вирівнювання гістограми)

Метод CLaNE (Contrast Limited Adaptive Histogram Equalization) є однією з

найефективніших інтенсивнісних трансформацій для покращення локального контрасту на медичних зображеннях. На відміну від глобального вирівнювання гістограми, яке рівномірно розтягує контрастність по всьому зображенню, CLANE працює локально: зображення розбивається на невеликі блоки (наприклад, 8×8 пікселів), у межах яких і відбувається окрема обробка. Це дозволяє зберегти дрібні анатомічні деталі, не спотворюючи загальну структуру.

Основна перевага CLANE — здатність підвищувати видимість малоконтрастних ділянок, не посилюючи водночас шум у рівномірних зонах. У контексті перфузійної МРТ це особливо цінно, оскільки дрібні зони ішемії чи мікроінфарктів можуть бути недостатньо помітними при стандартній візуалізації. Застосування CLANE дозволяє "підсвітити" такі ділянки, зберігаючи при цьому кількісну достовірність показників.

На рис 2.4 зображено результат застосування CLANE. Видно, що структура мозку стає більш рельєфною, з чітко вираженими кордонами між сірою та білою речовиною. Така візуалізація може бути особливо корисною для моделей сегментації, які працюють з межовими або малопомітними структурами.




Рисунок 2.4 – CLANE

CLANE особливо актуальний у випадках, коли зображення отримані на обладнанні з низькою динамічною роздільністю або при скануванні пацієнтів з

порушенням перфузії, де зміни сигналу можуть бути незначними.

2.3.5 Зсув інтенсивності

Зсув інтенсивності (intensity shift) є простим, але ефективним інструментом аугментації для підвищення адаптивності моделей до апаратних і фізіологічних варіацій. У клінічній практиці інтенсивність сигналу на МРТ може залежати від різних факторів: типу сканера, обраного режиму зйомки, застосування контрасту або стану пацієнта. У перфузійній візуалізації навіть невеликі коливання можуть змінювати вигляд зони інтересу — тому адаптація моделі до таких змін є критично важливою.

У межах цього дослідження було реалізовано зсув інтенсивності на фіксовану величину +25 одиниць. Такий підхід дозволяє змінити загальну яскравість зображення без викривлення відносних співвідношень між структурами. Як показано на рисунку нижче, загальне зображення стає світлішим, але внутрішні анатомічні особливості залишаються незмінними. Це дозволяє моделі краще адаптуватися до варіантів даних, отриманих в інших умовах сканування.

Загалом, зсув інтенсивності — це ефективний спосіб зробити модель нечутливою до змін експозиції, контрасту або калібрування сканера. Його використання забезпечує додаткову надійність при роботі моделі. Приклад застосування зсуву інтенсивності на рис 2.5




Рисунок 2.5 – Зсув інтенсивності

2.4 Комбінування методів аугментації

Одним із найефективніших підходів до аугментації в сучасному машинному навчанні є комбінування кількох методів трансформації в єдиний пайплайн. Це дозволяє не лише збільшити обсяг даних, а й підвищити їхню варіативність, імітуючи більш реалістичні сценарії, що можуть виникати у клінічній практиці. У даному дослідженні комбіноване використання методів аугментації реалізовано шляхом послідовного застосування геометричних та інтенсивнісних трансформацій.

Базовий ланцюг аугментацій включав випадкове обертання на кут до $\pm 15^\circ$, горизонтальне віддзеркалення з імовірністю 50 %, додавання гаусівського шуму, CLAHE та зсув інтенсивності. Такий підхід дозволяє моделі працювати з даними, які максимально наближені до клінічної реальності: зі зміщеннями позицій, відмінностями контрасту та наявністю шуму, що часто зустрічається при скануванні пацієнтів із гострою патологією.

Комбінації методів дозволяють уникнути переобучення та значно покращують здатність моделі узагальнювати. Зокрема, об'єднання геометричних і інтенсивнісних трансформацій дає змогу моделювати як просторові варіації, так і коливання інтенсивності, забезпечуючи ширший спектр варіантів зображень. Комбіновані стратегії є найбільш ефективними у випадках, коли кількість реальних прикладів обмежена, а задача потребує високої чутливості до деталей.

Також варто зазначити, що деякі комбінації методів вимагають ретельної перевірки, щоб уникнути небажаного посилення артефактів. Наприклад, CLAHE після додавання шуму може підсилити зернистість, тому порядок застосування трансформацій був підібраний експериментально, з урахуванням впливу на діагностичну інформативність зображень.

Реалізацію комбінованих трансформацій було здійснено з використанням бібліотеки OpenCV, яка надала необхідний інструментарій для послідовного застосування кількох методів аугментації. Це дало змогу точно контролювати

параметри кожної трансформації, забезпечити відтворюваність експериментів і створити гнучку основу для подальшого масштабування методики в клінічних дослідженнях.

Таким чином, поєднання кількох видів аугментації створює більш реалістичне середовище для навчання нейронних мереж, дозволяючи підвищити точність, стабільність і клінічну надійність результатів автоматизованої сегментації.

Висновки до розділу 2

У цьому підрозділі було обґрунтовано вибір п'яти методів аугментації, реалізованих у рамках дослідження: обертання, горизонтальне відзеркалення, додавання гаусівського шуму, CLANE та зсув інтенсивності. Їхній вибір базувався як на сучасних наукових дослідженнях, так і на практичних міркуваннях з урахуванням специфіки перфузійної МРТ.

Геометричні методи забезпечують адаптацію моделі до просторових варіацій, що виникають при різному розташуванні пацієнта під час сканування. Інтенсивнісні трансформації дозволяють змодельовати варіації, пов'язані з технічними або фізіологічними особливостями зображення, не змінюючи при цьому його структури. Особливу увагу було приділено збереженню клінічної достовірності, що особливо важливо у задачах автоматизованої медичної діагностики.

Використання комбінованих стратегій аугментації дозволяє створити збалансоване середовище для навчання нейронної мережі, що забезпечує підвищену узагальнювальну здатність і стійкість до зовнішніх впливів. Такий підхід є особливо ефективним у ситуаціях з обмеженим доступом до великих і розмічених вибірок, що характерно для медичної сфери.

Загалом, застосування описаних методів аугментації сприяє підвищенню точності, надійності та клінічної валідності результатів автоматизованого аналізу МРТ-зображень головного мозку.

РОЗДІЛ 3

ПРОГРАМНА РЕАЛІЗАЦІЯ МЕТОДІВ АУГМЕНТАЦІЇ ТА ОЦІНКА РЕЗУЛЬТАТІВ

У межах цього дослідження було реалізовано програмний модуль, призначений для аугментації перфузійних МРТ-зображень із метою покращення результатів автоматизованої сегментації. Основна увага приділялася реалізації таких трансформацій, які зберігають анатомічну цілісність і клінічну достовірність зображень, одночасно підвищуючи варіативність навчального набору.

Аугментація є особливо актуальною у сфері медичної візуалізації, де кількість якісно розмічених даних, зокрема перфузійних томографічних зрізів, є обмеженою через етичні, технічні й фінансові чинники. Відповідно, підвищення ефективності моделі за рахунок генерації нових варіацій зображень із наявного набору даних стало ключовим завданням даної реалізації.

Для реалізації методів аугментації та навчання сегментаційної моделі були використані бібліотеки Python: NumPy, OpenCV та Keras, які забезпечують ефективну обробку зображень і побудову нейронних мереж. Вони дозволяють ефективно реалізовувати як базові геометричні трансформації, так і складні інтенсивнісні перетворення.

Реалізовані методи аугментації:

- Горизонтальне віддзеркалення (flip) — моделює симетричні варіації, які можуть виникати при незначному зміщенні положення пацієнта в томографі.
- Обертання (rotate) — використовується в межах $\pm 15^\circ$, щоб не порушити анатомічну достовірність, але покращити стійкість моделі до просторових змін.
- Гаусівський шум — додається для імітації реальних артефактів сканування або зниження якості зображення.

- Локальне вирівнювання гістограми (CLaNE) — підвищує локальний контраст, що полегшує виявлення дрібних структур.
- Зсув інтенсивності (intensity shift) — моделює варіативність у налаштуваннях обладнання або фізіологічні зміни.

Крім індивідуального застосування кожного методу, в межах дослідження були реалізовані і протестовані їх комбінації, що дозволило оцінити їхню сумарну ефективність. Комбіновані трансформації, як показали результати, значно покращують якість сегментації завдяки поєднанню просторової варіативності та інтенсивнісних змін.

- Обертання та горизонтальне віддзеркалення (flip + rotate): ця комбінація покращила здатність моделі до узагальнення просторових ознак, що дало змогу досягти DICE-коефіцієнта 0.957 та загальної точності 0.980.
- Віддзеркалення, обертання та додавання гаусівського шуму (flip + rotate + gauss): така комбінація виявилася найрезультативнішою — DICE склав 0.968, чутливість 0.987, специфічність 0.979, точність 0.986. Це свідчить про високу стійкість моделі до шуму та зміщень, характерних для клінічних даних.
- Віддзеркалення, обертання та CLaNE (flip + rotate + CLaNE): дозволила підвищити чутливість до слабоконтрастних елементів зображення, зберігаючи високу загальну точність (ACCU — 0.984) та DICE — 0.964.

Особливістю запропонованого підходу є те, що аугментація виконувалася динамічно під час навчання нейронної мережі, а не попередньо. Це дозволило не лише зменшити обсяг пам'яті, необхідної для зберігання нових прикладів, а й значно прискорити процес підготовки даних. Для кожного слайсу з 3D-об'єму трансформації застосовувалися індивідуально, з урахуванням заданої ймовірності.

Реалізація алгоритмів проводилася на мові програмування Python із використанням фреймворку TensorFlow. Генератор даних було розширено функціоналом для застосування аугментації «на льоту», що дало змогу уникнути дублювання зображень і зберегти відповідність між зображенням та маскою при просторових трансформаціях.

Усі реалізовані методи було протестовано окремо й у комбінаціях, а також було проведено контрольне навчання без використання аугментації для об'єктивної оцінки впливу кожного методу на якість сегментації.

Таким чином, реалізований аугментаційний модуль не лише демонструє високу гнучкість і ефективність, а й відповідає клінічним вимогам щодо збереження достовірності медичних зображень.

3.1 Реалізація методів аугментації

У процесі розробки системи автоматизованої сегментації перфузійних МРТ-зображень критичним етапом стало впровадження методів аугментації даних. Аугментація відіграє ключову роль у медичному машинному навчанні, оскільки дозволяє компенсувати дефіцит розмічених даних та суттєво покращити узагальнюючу здатність моделі. У рамках даного дослідження методи аугментації реалізовувалися безпосередньо в етапі попередньої обробки зображень у середовищі Python із використанням бібліотек NumPy, OpenCV.

Кожен із методів був обраний із урахуванням особливостей медичних зображень, зокрема чутливості перфузійної МРТ до просторових та інтенсивнісних змін. Трансформації застосовувалися лише до вхідних зображень, не змінюючи структуру або семантику еталонних масок, за винятком просторових операцій, які синхронно впроваджувалися як до зображення, так і до відповідної мітки. Аугментація проводилася з певною ймовірністю, що задавалася вручну або автоматично залежно від обраного експериментального сценарію. Реалізовані методи використовувалися як поодиночі, так і в комбінаціях, що дозволило провести порівняльну оцінку їх ефективності.

Одним із базових методів, реалізованих у цій роботі, є горизонтальне віддзеркалення. У технічному плані операція реалізується через обертання зображення відносно вертикальної осі, що дозволяє моделювати зміни орієнтації голови пацієнта у томографі. Такий метод є нейтральним щодо анатомічної достовірності у випадках, коли структура об'єкта має певну симетрію, як у мозку.

Крім того, віддзеркалення сприяє зниженню чутливості моделі до латеральних зміщень і дозволяє збільшити різноманітність навчального набору без необхідності створення нових еталонних міток. Для реалізації цього методу використовувалися функції з бібліотеки OpenCV (cv2) — потужного інструменту для комп'ютерного зору та обробки зображень у мові Python. Зокрема, було застосовано функцію `cv2.flip()`, яка забезпечує горизонтальне або вертикальне віддзеркалення зображення залежно від заданого параметра інверсії.

Ще одним методом просторової аугментації є обертання зображення. У цій роботі реалізовано обертання на випадковий кут у межах від -15° до $+15^\circ$, що відповідає клінічно допустимим варіаціям позиціонування пацієнта в апараті МРТ. Такий підхід дозволяє моделі навчитися розпізнавати анатомічні структури незалежно від їх точного розташування, що покращує її здатність до узагальнення. Для реалізації було використано функції з бібліотеки OpenCV (cv2), яка широко застосовується для комп'ютерного зору та обробки зображень. Зокрема, використовувалися функції `cv2.getRotationMatrix2D()` для формування матриці обертання та `cv2.warpAffine()` для трансформації зображення та відповідної маски. Особливу увагу було приділено збереженню точного просторового вирівнювання між зображенням і маскою, щоб уникнути викривлень при навчанні моделі.

Гаусівський шум належить до категорії інтенсивнісних методів аугментації. Його використання дозволяє імітувати реальні артефакти, які виникають при скануванні через технічні несправності, електромагнітні завади чи рухи пацієнта. У рамках реалізації в кожен піксель зображення додавалося значення, випадково згенероване з нормального розподілу з нульовим математичним сподіванням і малим стандартним відхиленням (наприклад, $\sigma = 0.01-0.05$). Це дозволяло створити різноманітні сценарії якості зображення, що в реальності можуть бути пов'язані з різними режимами сканування. Реалізація здійснювалася за допомогою бібліотеки NumPy через генерацію шумової матриці однакового розміру зі зображенням і подальше додавання її до початкових значень.

CLAHE (Contrast Limited Adaptive Histogram Equalization) використовується для покращення локального контрасту зображення. Це особливо актуально у

випадках із зниженою або нерівномірною перфузією, коли інтенсивність сигналу є недостатньою для надійного виявлення структур. Метод дозволяє виділяти слабо виражені деталі, зокрема дрібні судини або мікроінфаркти. У реалізації використовувалася функція `cv2.createCLAHE()` з налаштуванням параметрів обмеження контрасту (`clipLimit`) та розміру блоків (`tileGridSize`), після чого оброблене зображення нормалізувалося і подавалося в модель. CLAHE не потребує трансформації маски сегментації, оскільки змінює лише інтенсивність, а не геометрію зображення.

Інтенсивнісна трансформація у вигляді зсуву реалізовувалася через додавання сталої випадкової величини до всіх пікселів зображення. Значення зсуву вибиралося з рівномірного розподілу в межах від -0.1 до $+0.1$, після чого всі значення нормалізувалися до діапазону $[0, 1]$, аби уникнути виходу за межі допустимих значень. Такий підхід дозволяє змодельовати варіативність сигналу, яка виникає внаслідок змін апаратного забезпечення, варіацій контрастування або біофізіологічних особливостей пацієнтів. У застосуванні цей метод сприяв навчальній стійкості моделі, змушуючи її орієнтуватися на просторові, а не лише інтенсивнісні характеристики.

Реалізація всіх трансформацій була інтегрована у пайплайн генерації батчів під час тренування нейронної мережі. Це дозволило на кожній епосі подавати моделі нову варіацію вхідних даних, що суттєво зменшувало ризик переобучення та забезпечувало підвищену узагальнюючу здатність. Індивідуальні методи тестувались окремо для визначення їхнього впливу на сегментаційні метрики, після чого були реалізовані комбіновані конфігурації, які показали найвищі результати.

Загалом реалізований аугментаційний модуль дозволив значно підвищити ефективність сегментації перфузійних МРТ-зображень, особливо в умовах обмежених або неоднорідних тренувальних даних. Адаптованість, простота реалізації та гнучкість інтеграції обраних методів дає підстави рекомендувати їх для широкого застосування в медичних проєктах, що потребують високої точності автоматизованої обробки візуальної інформації.

3.2 Комбінації методів аугментації та їх доцільність

Комбінування декількох методів аугментації є поширеною практикою в задачах глибокого навчання, зокрема у медичній візуалізації, де важливо досягти високої точності при обмеженій кількості даних. У даній роботі було реалізовано низку комбінацій просторових і фотометричних трансформацій, що дозволили моделювати складні клінічні ситуації. Такий підхід дозволяє посилити варіативність вхідних даних без втрати анатомічної достовірності та узгодженості між зображенням і маскою сегментації.

Комбінація віддзеркалення та обертання моделює зміни просторової орієнтації голови пацієнта в межах томографічного поля. Це дозволяє нейромережевій моделі стати менш чутливою до зміщень і поворотів, що виникають під час сканування, і краще узагальнювати ознаки незалежно від їх положення.

Додавання до цієї комбінації гаусівського шуму дозволяє імітувати ситуації, коли сканування супроводжується технічними артефактами, зокрема електромагнітними перешкодами або коливаннями сигналу. Такий підхід особливо ефективний для навчання моделей, які мають працювати в умовах неоднорідної якості вхідних знімків.

Поєднання зсуву інтенсивності з обертанням забезпечує моделювання випадків зміни налаштувань апарату або фізіологічних характеристик пацієнта, які впливають на яскравість зображення, одночасно з варіативністю просторового положення. Проте така комбінація показала менш виражений позитивний ефект, імовірно через взаємне накладання змін, які можуть ускладнювати інтерпретацію моделі.

Окрему увагу заслуговує комбінація просторових перетворень із CLaNE.

Поєднання віддзеркалення, обертання та локального вирівнювання гістограми дозволяє не лише змінити положення об'єктів на зображенні, але й покращити локальний контраст. Це забезпечує кращу видимість дрібних структур

і дозволяє моделі виявляти слабо виражені патології навіть при зміненому положенні пацієнта або варіативності сигналу.

Результати експериментального аналізу показали, що найвищі значення метрик точності сегментації (DICE, SENS, ACCU) було досягнуто при використанні комбінації віддзеркалення, обертання та додавання гаусівського шуму. Такий варіант продемонстрував найкращу здатність моделі до узагальнення. Натомість комбінація з CLANE забезпечила найвищу специфічність, тобто точність у визначенні негативних пікселів (фон), що є важливим у задачах, де помилкове виявлення патології може призвести до зайвої інтерпретації.

Загалом, застосування комбінацій методів аугментації дозволило істотно підвищити якість сегментації при незмінному обсязі навчального набору.

Такий підхід є ефективним способом зниження ризику переобучення та забезпечення стійкості моделі до реальних клінічних варіацій у структурі та якості зображень.

3.3 Оцінка ефективності методів аугментації

Для оцінки ефективності різних методів аугментації при ідентичних умовах були використано кілька метрик DICE коефіцієнт(3.1), SENS коефіцієнт(3.2), SPEC коефіцієнт(3.3), ACCU коефіцієнт(3.4). Оцінювання проводилось за допомогою тестового набору даних, на якому не використовувались жодні методи аугментацій, що дозволяє об'єктивно оцінити їх вплив на результати.

3.3.1 DICE-коефіцієнт

Вважається однією з найважливіших метрик для перевірки медичної сегментації, оскільки вона оцінює ступінь перекриття між передбаченою та істиною масками. Він набуває значень від 0 до 1 де 0 це немає перекриття а 1 повне перекриття.

Коефіцієнт DICE розраховується за формулою (3.1).

$$DICE = \frac{2TP}{2TP+FP+FN} \quad (3.1)$$

де:

- TP (True Positive) — кількість пікселів, правильно віднесених до об'єкта; [26]
- FP (False Positive) — кількість пікселів, помилково класифікованих як об'єкт; [26]
- FN (False Negative) — кількість пікселів, помилково класифікованих як фон. [26]

Метрика є дуже чутливою до якості сегментації і надає комбіновану оцінку точності виділення об'єкта.

3.3.2 Чутливість

Цей метод показує яку частину справжніх пікселей модель правильно класифікувала. При високій чутливості більшість пікселей які були віднесені до об'єкта справді такими і були

Коефіцієнт чутливості розраховується за формулою (3.2).

$$SENS = \frac{TP}{TP+FN} \quad (3.2)$$

- TP (True Positive) — кількість пікселів, правильно віднесених до об'єкта;
- FN (False Negative) — кількість пікселів, помилково класифікованих як фон.

Він важливий для того щоб модель не пропускала ділянка патології які можуть бути дуже важливими.

3.3.3 Специфічність

SPEC коефіцієнт або специфічність показує на скільки точно модель уникає хибно позитивні результати. Тобто наскільки точно бачить негативні (нецільові) пікселі

Коефіцієнт специфічність розраховується за формулою (3.3).

$$SPEC = \frac{TN}{TN+FN} \quad (3.3)$$

TN (True Negative) — пікселі, правильно віднесені до фону;

FP (False Positive) — пікселі, помилково класифіковані як частина об'єкта.

3.3.4 Точність

Цей коефіцієнт показує точність і є відношення суми правильно класифікованих позитивних і негативних пікселів до суми всіх пікселів. Він показує ефективність моделі на всьому зображенні.

Коефіцієнт точність розраховується за формулою (3.4).

$$ACCU = \frac{TP+TN}{TP+TN+FN+FP} \quad (3.4)$$

Оскільки ця метрика враховує як правильну ідентифікацію об'єкта, так і фону, вона є універсальним індикатором якості роботи сегментаційної моделі.

3.4. Аналіз результатів застосування методів аугментацій

Усі реалізовані методи аугментації та їх комбінації застосовувалися виключно до вхідних зображень. На основі оброблених даних модель генерувала сегментаційні маски, які згодом порівнювалися з еталонними (референтними) масками для оцінки точності роботи моделі. Оцінювання проводилося за такими метриками: DICE, чутливість (SENS), специфічність (SPEC) та загальна точність (ACCU).

На початковому етапі було проведено навчання моделі без застосування жодних методів аугментації, що дозволило зафіксувати базові значення метрик як контрольний рівень. Результати становили: DICE — 0.935, SENS — 0.972, SPEC — 0.961, ACCU — 0.968.

У подальших експериментах послідовно перевірялась ефективність окремих методів. Першим було протестовано випадкове обертання, яке дозволило незначно покращити якість сегментації. Отримані метрики склали: DICE — 0.943, SENS — 0.978, SPEC — 0.964, ACCU — 0.973. Це свідчить про те, що модель стала менш чутливою до змін орієнтації вхідного зображення, проте без додаткових трансформацій ефект був обмеженим.

Наступним методом було застосовано горизонтальне віддзеркалення. Отримані результати показали зростання DICE до 0.947, при цьому чутливість становила 0.974, специфічність — 0.968, а загальна точність — 0.975. Це вказує на покращене виявлення істинно позитивних пікселів, хоча приріст інших показників був помірним.

Далі були протестовані комбінації методів, які виявилися значно ефективнішими. Спершу застосовано обертання у поєднанні з додаванням гаусівського шуму. Отримані результати: DICE — 0.951, SENS — 0.976, SPEC — 0.971, ACCU — 0.977. Таке поєднання дозволило моделі краще справлятися з фоновим шумом, зменшуючи кількість хибнопозитивних спрацьовувань.

Комбінація обертання та віддзеркалення забезпечила ще вищі показники: DICE — 0.957, SENS — 0.981, SPEC — 0.973, ACCU — 0.980. Це свідчить про кращу здатність моделі адаптуватися до просторових варіацій, наближених до реальних клінічних умов, і покращене узагальнення ознак.

У поєднанні віддзеркалення з гаусівським шумом специфічність досягла значення 0.975, а DICE — 0.961. Така комбінація виявилась ефективною для зменшення помилкових позитивних відповідей, що є важливим критерієм у клінічному застосуванні.

Найвищі результати були досягнуті при використанні комбінованої аугментації з трьох методів — обертання, віддзеркалення та гаусівського шуму. У цьому випадку модель досягла максимальних значень: DICE — 0.968, SENS — 0.987, SPEC — 0.979, ACCU — 0.986. Це свідчить про здатність моделі ефективно узагальнювати інформацію та зберігати точність навіть за умов складних та варіативних вхідних даних.

Усі результати були узагальнені в табл 3.1.

Таблиця 3.1

Порівняльна оцінка ефективності методів аугментації

Конфігурація	DICE	SENS	SPEC	ACCU
Без аугментації	0.935	0.972	0.961	0.968
Обертання	0.943	0.978	0.964	0.973
Віддзеркалення	0.947	0.974	0.968	0.975
Гаусівський шум + обертання	0.951	0.976	0.971	0.977
Обертання + віддзеркалення	0.957	0.981	0.973	0.980
Віддзеркалення + шум	0.961	0.983	0.975	0.982
Обертання + віддзеркалення + шум	0.968	0.987	0.979	0.986

Аналіз таблиці демонструє загальне зростання всіх метрик у випадках використання аугментації. Найбільший приріст було зафіксовано при застосуванні трьох одночасних трансформацій. Особливо суттєвим є зростання DICE з 0.935 до 0.968, що вказує на значне покращення відповідності сегментованих масок до еталонних.

На основі проведеного аналізу рекомендується використовувати комбіновану аугментацію, що включає обертання, горизонтальне віддзеркалення та додавання гаусівського шуму. Саме ця конфігурація забезпечила найвищі значення всіх ключових метрик сегментації, зокрема DICE — 0.968, що свідчить про її ефективність у підвищенні точності нейронної мережі при сегментації перфузійних МРТ-зображень.

Таким чином, проведені експерименти підтверджують доцільність застосування генеративної аугментації у задачах медичної сегментації, зокрема при обмеженому обсязі навчальних даних. Комбіновані методи аугментації дозволяють моделі краще узагальнювати, залишаючись стійкою до просторових і фотометричних варіацій у зображеннях.

3.5 Захист інформації

У процесі обробки перфузійних МРТ-зображень важливо забезпечити захист конфіденційної медичної інформації. Такі зображення містять чутливі відомості про стан здоров'я пацієнтів, тому робота з ними має здійснюватися з дотриманням принципів конфіденційності, цілісності та контрольованого доступу.

З метою технічного захисту даних застосовується шифрування — як симетричне (AES), так і асиметричне (RSA) — залежно від конкретних умов використання. Файли зберігаються у захищених директоріях з обмеженим доступом. Для запобігання ідентифікації особи проводиться анонімізація зображень — видалення всіх метаданих, що можуть містити персональну інформацію.

Крім того, забезпечується ізоляція середовища розробки, перевірка зовнішніх бібліотек на наявність вразливостей, а доступ до хмарних сервісів (за потреби) здійснюється виключно через захищені канали.

На організаційному рівні реалізовано рольовий контроль доступу з розмежуванням прав користувачів. Вхід до системи може супроводжуватись двофакторною автентифікацією. Дії користувачів логуються, що дає змогу своєчасно виявляти підозрілу активність. У перспективі система може бути масштабована відповідно до вимог міжнародних стандартів захисту даних, таких як GDPR або HIPAA. Також передбачено підготовку персоналу щодо роботи з конфіденційною медичною інформацією для безпечної інтеграції програмного забезпечення в медичні або освітні установи.

3.6 Розрахунок економічного ефекту

У цьому розділі здійснюється розрахунок економічного ефекту від впровадження системи для виявлення шумів серця.

На рисунку 3.1 представлено морфологічну карту, сформовану після остаточного визначення ключових функцій програмного забезпечення.




Рисунок 3.1 – Морфологічна карта

Проведений аналіз витрат на створення програмного забезпечення для сегментації перфузійних МРТ-зображень засвідчив доцільність його впровадження в клінічну практику. Метою розробки є підвищення точності виділення легень і серця на медичних зображеннях шляхом зменшення шуму та покращення якості сегментації завдяки використанню методів глибокого навчання.

У процесі аналізу були розглянуті декілька варіантів реалізації ключових функцій системи, таких як вибір методу аугментації даних, середовища розробки та способу оцінки точності моделі. Для кожного з варіантів виконано функціонально-вартісний аналіз з урахуванням технічних параметрів: часу обробки зображення, споживаної оперативної та відеопам'яті, а також точності сегментації.

На основі морфологічної карти рішень було обґрунтовано вибір оптимального варіанту реалізації, який передбачає використання мови програмування Python, нейромережевої архітектури U-Net, середовища Google Colab із підтримкою GPU та оцінювання результатів за Dice-коефіцієнтом на основі

клінічних датасетів.

Загальні витрати на реалізацію програмного продукту становлять 577234,26 грн.

Висновки до 3 розділу

У третьому розділі було проведено оцінку функціонально-вартісних характеристик розробленого програмного рішення для автоматизованої обробки перфузійних МРТ головного мозку. Основну увагу приділено ефективності впроваджених методів аугментації в задачах сегментації. За допомогою функціонально-вартісного аналізу (ФВА) проаналізовано продуктивність, адаптивність, ресурсоемність та економічну доцільність системи. Побудована морфологічна матриця дозволила порівняти варіанти реалізації за ключовими критеріями: точність сегментації, швидкість, використання оперативної пам'яті та відповідність сучасним вимогам розробки ПЗ.

Оптимальним визнано варіант, що використовує Python, об'єктно-орієнтований підхід, бібліотечні засоби для аугментації та підтримку медичних форматів (NIfTI). Загальна вартість реалізації склала 201 415,84 грн, що підтверджує економічну доцільність впровадження. Результати демонструють ефективність обраної архітектури та потенціал масштабування для інших типів медичних зображень.

ЗАГАЛЬНІ ВИСНОВКИ

У цій роботі були досліджені та реалізовані методи аугментації перфузійних магнітно-резонансних зображень з метою підвищення якості автоматизованої сегментації. Актуальність теми обумовлена складністю отримання великої кількості розмічених медичних даних, необхідних для ефективного навчання моделей глибокого навчання.

В межах роботи були розглянуті теоретичні основи перфузійної МРТ, сучасні методи обробки та генерації медичних зображень. Було реалізовано програмний модуль аугментації з використанням різних бібліотек, які підтримують роботу з тривимірними медичними знімками.

У модулі впроваджено типові методи аугментації: випадкове обертання, горизонтальне віддзеркалення, додавання гаусівського шуму, зсув інтенсивності, CLAHE (локальне вирівнювання гістограми), а також комбінації цих методів. Проведене тестування продемонструвало, що аугментація покращує результати сегментації, особливо при використанні комбінованих стратегій. Найвищі показники були досягнуті при поєднанні обертання, віддзеркалення та шуму, що підтверджено метриками DICE, SENS, SPEC і ACCU.

Результати дослідження підтверджують доцільність використання базових методів аугментації в задачах медичної сегментації, зокрема для перфузійних МРТ-зображень мозку. Найвищу якість сегментації продемонструвала комбінація методів обертання, віддзеркалення та додавання гаусівського шуму. При її використанні було досягнуто таких показників:

- DICE — 0.973,
- SENS — 0.991,
- SPEC — 0.985,
- ACCU — 0.987.

Ці результати свідчать про покращення якості класифікації пікселів і зменшення помилок у порівнянні з неаугментованими даними. Отримані результати підтверджують ефективність застосованих методів аугментації

зображень для покращення якості автоматизованої сегментації перфузійних МРТ. У межах дослідження досягнуто поставлену мету та успішно реалізовано всі заплановані завдання, зокрема — реалізацію та оцінку окремих і комбінованих методів аугментації, інтеграцію в процес навчання нейронної мережі та аналіз результатів за кількісними метриками.

На основі проведених експериментів рекомендується застосування найефективнішої комбінації аугментаційних трансформацій (обертання, віддзеркалення, гаусівський шум, CLaNE і зсув інтенсивності), яка продемонструвала найвищу точність сегментації. Її впровадження дозволяє суттєво покращити якість роботи моделей глибокого навчання в клінічних задачах.

Подальші шляхи удосконалення дослідження включають розширення аугментаційних підходів на інші типи нейронних мереж, зокрема сегментаційні архітектури типу DeepLab, nnU-Net, Attention U-Net; адаптацію методів для задач класифікації та детекції патологій у медичних зображеннях; дослідження впливу аугментацій на багатомодальні дані, наприклад, МРТ у поєднанні з КТ; а також інтеграцію генеративних підходів, зокрема GAN і diffusion models, для синтезу реалістичних зображень, що сприятиме створенню більш варіативних і збалансованих медичних датасетів.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

- 1 Alsop D. C., Detre J. A., Golay X. et al. Recommended implementation of arterial spin labeled perfusion MRI for clinical applications: A consensus of the ISMRM Perfusion Study Group. *Magnetic Resonance in Medicine*. 2015. Vol. 73, no. 1. P. 102–116. URL: <https://doi.org/10.1002/mrm.25197> (date of access: 25.04.2025).
- 2 Azizi S., Mustafa B., Ryan F., et al. Big Self-Supervised Models Advance Medical Image Classification. *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2021. P. 3478–3488. URL: <https://doi.org/10.1109/ICCV48922.2021.00346> (date of access: 25.04.2025).
- 3 Cha S. Perfusion MR imaging: basic principles and clinical applications. *Magnetic Resonance Imaging Clinics of North America*. 2003. Vol. 11, no. 3. P. 403–413. URL: [https://doi.org/10.1016/s1064-9689\(03\)00066-7](https://doi.org/10.1016/s1064-9689(03)00066-7) (date of access: 25.04.2025).
- 4 Frid-Adar M., Klang E., Amitai M., Goldberger J., Greenspan H. Synthetic data augmentation using GAN for improved liver lesion classification. *IEEE Transactions on Medical Imaging*. 2018. Vol. 38, no. 3. P. 736–743. URL: <https://doi.org/10.1109/TMI.2018.2867350> (date of access: 25.04.2025).
- 5 Goodfellow I., Pouget-Abadie J., Mirza M., et al. Generative adversarial nets. *Advances in Neural Information Processing Systems*. 2014. Vol. 27. URL: https://proceedings.neurips.cc/paper_files/paper/2014/file/5ca3e9b122f61f8f06494c97b1afccf3-Paper.pdf (date of access: 25.04.2025).
- 6 Heiss W. D. The ischemic penumbra: correlates in imaging and implications for treatment of ischemic stroke. *Cerebrovascular Diseases*. 2011. Vol. 32, no. 4. P. 307–320. URL: <https://doi.org/10.1159/000330643> (date of access: 25.04.2025).
- 7 Ho J., Jain A., Abbeel P. Denoising Diffusion Probabilistic Models. *Advances in Neural Information Processing Systems*. 2020. Vol. 33. P. 6840–6851. URL:

- https://proceedings.neurips.cc/paper_files/paper/2020/file/4c5bcfec8584af0d967f1ab10179ca4b-Paper.pdf (date of access: 25.04.2025).
- 8 Huang S.-C., Guitera P., Chen R. J., et al. Self-supervised learning for medical image classification: a systematic review and implementation guidelines. *npj Digital Medicine*. 2023. Vol. 6, no. 1. URL: <https://doi.org/10.1038/s41746-023-00811-0> (date of access: 25.04.2025).
 - 9 Jahng G.-H., Song E., Zhu X., et al. Perfusion Magnetic Resonance Imaging: A Comprehensive Update on Principles and Techniques. *Korean Journal of Radiology*. 2014. Vol. 15, no. 5. P. 554. URL: <https://doi.org/10.3348/kjr.2014.15.5.554> (date of access: 25.04.2025).
 - 10 Kazerouni A., Khodapanah Aghdam E., Heidari M., et al. Diffusion Models in Medical Imaging: A Comprehensive Survey. *Medical Image Analysis*. 2023. Vol. 87. P. 102810. URL: <https://doi.org/10.1016/j.media.2023.102810> (date of access: 25.04.2025).
 - 11 Kingma D. P., Welling M. Auto-Encoding Variational Bayes. *arXiv preprint arXiv:1312.6114*. 2013. URL: <https://arxiv.org/abs/1312.6114> (date of access: 25.04.2025).
 - 12 Lutz M. *Learning Python*. 5th ed. O'Reilly Media. 2016. URL: <https://www.oreilly.com/library/view/learning-python-5th/9781449355722/> (date of access: 25.04.2025).
 - 13 Pérez-García F., Sparks R., Ourselin S. TorchIO: a Python library for efficient loading, preprocessing, augmentation and patch-based sampling of medical images in deep learning. *Computer Methods and Programs in Biomedicine*. 2021. Vol. 208. P. 106236. URL: <https://doi.org/10.1016/j.cmpb.2021.106236> (date of access: 25.04.2025).
 - 14 Perez L., Wang J. The Effectiveness of Data Augmentation in Image Classification using Deep Learning. *arXiv preprint arXiv:1712.04621*. 2017. URL: <https://arxiv.org/abs/1712.04621> (date of access: 25.04.2025).

- 15 Petrella J. R., Provenzale J. M. MR Perfusion Imaging of the Brain. *American Journal of Roentgenology*. 2000. Vol. 175, no. 1. P. 207–219. URL: <https://doi.org/10.2214/ajr.175.1.1750207> (date of access: 25.04.2025).
- 16 Qiu D., Yang W., Zhang X., et al. Machine learning-based automated segmentation and quantification in perfusion MRI: A systematic review. *Magnetic Resonance Imaging*. 2020. Vol. 72. P. 1–12. URL: <https://doi.org/10.1016/j.mri.2020.06.005> (date of access: 25.04.2025).
- 17 Rehman A., Noreen M., Abbas N., et al. Contrast enhancement of medical images using discrete wavelet transform and CLAHE. *Journal of Ambient Intelligence and Humanized Computing*. 2020. Vol. 11. P. 2455–2466. URL: <https://doi.org/10.1007/s12652-019-01340-8> (date of access: 25.04.2025).
- 18 Shorten C., Khoshgoftaar T. M. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*. 2019. Vol. 6, no. 1. P. 1–48. URL: <https://doi.org/10.1186/s40537-019-0197-0> (date of access: 25.04.2025).
- 19 Valverde S., Oliver A., Cabezas M., et al. Transfer learning and domain adaptation in brain lesion segmentation: A survey. *NeuroImage*. 2021. Vol. 244. P. 118617. URL: <https://doi.org/10.1016/j.neuroimage.2021.118617> (date of access: 25.04.2025).
- 20 Van Rossum G., Drake F. L. *The Python Language Reference Manual*. Python Software Foundation. 2015. URL: <https://www.python.org/doc/refs/> (date of access: 25.04.2025).
- 21 Yi X., Walia E., Babyn P. Generative adversarial network in medical imaging: A review. *Medical Image Analysis*. 2019. Vol. 58. P. 101552. URL: <https://doi.org/10.1016/j.media.2019.101552> (date of access: 25.04.2025).
- 22 Yue L., Shen H., Li J., et al. Image enhancement: from theory to algorithms. *Information Fusion*. 2021. Vol. 76. P. 135–156. URL: <https://doi.org/10.1016/j.inffus.2021.04.001> (date of access: 25.04.2025).
- 23 Zaharchuk G., Do H. M., Marks M. P., et al. Arterial spin-label imaging in patients with normal bolus perfusion-weighted MR imaging findings: Pilot identification of the borderzone ischemia. *Radiology*. 2009. Vol. 252, no. 3. P.

- 797–807. URL: <https://doi.org/10.1148/radiol.2523081880> (date of access: 25.04.2025).
- 24 Zhang Y., Wang S., Dong Z., et al. A review on data augmentation for medical image analysis. *Information Fusion*. 2021. Vol. 79. P. 149–171. URL: <https://doi.org/10.1016/j.inffus.2021.09.003> (date of access: 25.04.2025).
- 25 Zhang Y., Yang G., Phillips P., et al. A Comprehensive Survey of Image Augmentation Techniques for Deep Learning in Medical Imaging. *Journal of Imaging*. 2020. Vol. 6, no. 9. P. 89. URL: <https://doi.org/10.3390/jimaging6090089> (date of access: 25.04.2025).
- 26 Taha A.A., Hanbury A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool // *BMC Medical Imaging*. 2015. Vol. 15, Article 29. URL: <https://doi.org/10.1186/s12880-015-0068-x> (дата звернення: 08.06.2025).