

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)

Кафедра Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)

Дослідження методів штучного інтелекту для аналізу МРТ-зображень
при діагностуванні нейродегенеративних захворювань
ГОЛОВНОГО МОЗКУ
(тема)

Виконав:
студент 2 курсу, групи СШМ-22-1
Любацький А.В.
(прізвище, ініціали)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)

Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи штучного інтелекту

(повна назва спеціалізації)
Керівник доц. Селіванова К.Г.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри _____
(підпис)

В.О. Філатов
(прізвище, ініціали)

2024 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)
Кафедра Штучного інтелекту
(повна назва)
Рівень вищої освіти другий (магістерський)
Спеціальність 122 Комп'ютерні науки
(код і повна назва)
Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)
Освітня програма Системи штучного інтелекту
(повна назва)

ЗАТВЕРДЖУЮ:
Зав. кафедри _____
(підпис)
«_____» _____ 20__ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові Любацькому Артему Володимировичу
(прізвище, ім'я, по батькові)

1. Тема роботи Дослідження методів штучного інтелекту для аналізу МРТ-зображень при діагностуванні нейродегенеративних захворювань головного мозку

затверджена наказом університету від 1 квітня 20 24 р. № 260Ст

2. Термін подання студентом роботи до екзаменаційної комісії 14 червня 20 24 р.

3. Вихідні дані до роботи науково-технічні публікації, дані Інтернет-джерел, відкритий набір даних з Kaggle, Python-документація, документація для бібліотек аналізу та обробки даних

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Аналіз предметної галузі та постановка задачі дослідження

2) Методи обробки МРТ-зображень

3) Методи штучного інтелекту для аналізу МРТ-зображень

4) Практична реалізація

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	01.04.2024	виконано
2	Проведення початкового аналізу теми та визначення основних напрямків дослідження	02.04.2024 – 05.04.2024	виконано
3	Збір та систематизація наукових джерел, літератури та даних	06.04.2024 – 10.04.2024	виконано
4	Огляд методів обробки МРТ-зображень	11.04.2024 – 18.04.2024	виконано
5	Дослідження методів штучного інтелекту для аналізу МРТ-зображень	19.04.2024 – 09.05.2024	виконано
6	Виконання експериментальних досліджень	10.05.2024 – 17.05.2024	виконано
7	Аналіз отриманих результатів	18.05.2024 – 19.05.2024	виконано
8	Оформлення пояснювальної записки	20.05.2024 – 31.05.2024	виконано
9	Проходження нормоконтролю	01.06.2024 – 08.06.2024	виконано
10	Рецензування	10.06.2024	виконано
11	Захист кваліфікаційної роботи	14.06.2024	

Дата видачі завдання 1 квітня 2024 р.

Студент _____
(підпис)

Керівник роботи _____ доц. Селіванова К.Г.
(підпис) (посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка: 99 с., 49 рис., 1 табл., 1 дод., 47 джерел.

АНАЛІЗ ЗОБРАЖЕНЬ, ГЛИБИННЕ НАВЧАННЯ, КОМП'ЮТЕРНИЙ ЗІР, МАГНІТНО-РЕЗОНАНСНА ТОМОГРАФІЯ, НЕЙРОВІЗУАЛІЗАЦІЯ, НЕЙРОДЕГЕНЕРАТИВНІ ЗАХВОРЮВАННЯ, НЕЙРОННІ МЕРЕЖІ, ШТУЧНИЙ ІНТЕЛЕКТ.

Об'єкт дослідження – процес виявлення нейродегенеративних захворювань головного мозку за допомогою аналізу МРТ-зображень.

Предмет дослідження – методи штучного інтелекту, що застосовуються для аналізу МРТ-зображень з метою діагностики та моніторингу нейродегенеративних захворювань головного мозку.

Мета роботи – дослідження та оцінка потенціалу застосування методів штучного інтелекту для аналізу МРТ-зображень у діагностиці нейродегенеративних захворювань головного мозку.

Методи дослідження – аналіз та систематизація теоретичного матеріалу, проведення та аналіз експериментів.

Нейродегенеративні захворювання, такі як хвороба Паркінсона, хвороба Альцгеймера та інші, представляють складність не тільки у їх діагностиці, але й у розумінні механізмів розвитку. Вони впливають на різні аспекти життя пацієнтів, від когнітивних функцій до фізичної активності, вимагаючи комплексного підходу до лікування.

Використання штучного інтелекту для аналізу МРТ-зображень може значно підвищити точність і швидкість діагностики цих захворювань. Огляд сучасних досліджень, присвячених цій тематиці, показав, що методи штучного інтелекту, зокрема згорткові нейронні мережі (CNN), демонструють високу ефективність у цій галузі.

ABSTRACT

Master's thesis contains: 99 pp., 49 fig., 1 tabl., 1 ann., 47 references.

ARTIFICIAL INTELLIGENCE, COMPUTER VISION, DEEP LEARNING, IMAGE ANALYSIS, MAGNETIC RESONANCE IMAGING, NEURAL NETWORKS, NEURODEGENERATIVE DISEASES, NEUROIMAGING.

The object of the research is the process of detecting neurodegenerative diseases of the brain through MRI image analysis.

The subject of the research is the artificial intelligence methods applied to MRI image analysis for the diagnosis and monitoring of neurodegenerative diseases of the brain.

The aim of the work is to study and evaluate the potential of artificial intelligence methods for MRI image analysis in the diagnosis of neurodegenerative diseases of the brain.

Research methods – analysis and systematization of theoretical material, conducting and analyzing experiments.

Neurodegenerative diseases, such as Parkinson's disease, Alzheimer's disease, and others, present challenges not only in their diagnosis but also in understanding the mechanisms of their development. They affect various aspects of patients' lives, from cognitive functions to physical activity, requiring a comprehensive approach to treatment.

The use of artificial intelligence for MRI image analysis can significantly improve the accuracy and speed of diagnosing these diseases. A review of current research on this topic has shown that artificial intelligence methods, particularly convolutional neural networks (CNNs), demonstrate high efficiency in this field.

ЗМІСТ

Вступ.....	8
1 Аналіз предметної галузі та постановка задачі дослідження.....	9
1.1 Нейродегенеративні захворювання, їх типи та причини виникнення. 9	
1.2 Огляд існуючих методів використання штучного інтелекту для аналізу МРТ-зображень.....	14
1.3 Постановка задачі дослідження.....	24
2 Методи обробки МРТ-зображень.....	25
2.1 Техніки передобробки зображень.....	25
2.1.1 Фільтрація шумів.....	25
2.1.2 Корекція контрасту.....	30
2.1.3 Нормалізація зображень.....	35
2.1.4 Вирівнювання гомогенності.....	37
2.2 Алгоритми обробки та аналізу зображень.....	38
2.2.1 Сегментація зображень.....	38
2.2.2 Виділення ознак.....	43
3 Методи штучного інтелекту для аналізу МРТ-зображень.....	46
3.1 Алгоритми машинного навчання для обробки медичних зображень 46	
3.1.1 Древа рішень.....	46
3.1.2 Метод опорних векторів.....	50
3.1.3 Байєсові мережі.....	53
3.1.4 Рандомні ліси.....	56
3.1.5 Лінійна регресія та логістична регресія.....	58
3.1.6 Градієнтний бустинг.....	61
3.1.7 К-найближчих сусідів.....	62
3.2 Глибинне навчання та нейронні мережі.....	64
3.2.1 Згорткові нейронні мережі.....	64
3.2.2 Автокодувальники.....	67
3.2.3 Рекурентні нейронні мережі.....	69

3.3 Порівняння методів штучного інтелекту для аналізу медичних зображень	73
3.4 Метрики оцінки ефективності	75
4 Практична реалізація	79
4.1 Попередня обробка даних	80
4.2 Експлоративний аналіз	81
4.3 Розробка та навчання моделей.....	83
4.4 Аналіз результатів.....	86
Висновки	91
Перелік джерел посилання	93
Додаток А Відомість кваліфікаційної роботи	99

ВСТУП

Нейродегенеративні захворювання вимагають значної уваги в сучасному світі, оскільки вони вражають життя мільйонів людей, призводячи до поступової втрати нейронів та зміни мозкової структури. Це призводить до зниження якості життя пацієнтів, а також створює значне навантаження на системи охорони здоров'я по всьому світу. Важливість своєчасного виявлення та точної діагностики цих захворювань не може бути переоцінена, адже вони характеризуються складними і різноманітними симптомами, які часто розвиваються непомітно та мають суттєві варіації між пацієнтами.

Магнітно-резонансна томографія є невід'ємною частиною процесу діагностики, оскільки надає детальні зображення внутрішніх структур мозку з високою роздільною здатністю, що є ключовим для виявлення анатомічних та функціональних змін, асоційованих з нейродегенеративними процесами. Однак, аналіз МРТ-зображень, що виконується вручну медичними спеціалістами, вимагає значних зусиль та може нести в собі елемент суб'єктивності, що іноді призводить до неоднозначності у діагностичних оцінках. Це, в свою чергу, може вести до розходжень у прийнятті рішень стосовно лікування, підкреслюючи потребу у більш уніфікованих та об'єктивних методах діагностики.

Штучний інтелект (ШІ) відкриває нові можливості для вдосконалення діагностики, надаючи інструменти для автоматизованого та точного аналізу медичних зображень. Завдяки розвитку алгоритмів машинного зору та навчання, ШІ може виявляти складні wzірці, які людське око може не помітити. Впровадження ШІ у процес аналізу МРТ-зображень дозволяє значно підвищити точність діагностики, скоротити час обробки даних та зменшити людський фактор, який може призводити до помилок.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ ТА ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ

Нейродегенеративні захворювання (НДЗ) представляють значний виклик для медичної науки та клінічної практики по всьому світу. З одного боку, постійне старіння населення збільшує кількість людей, схильних до таких станів, що вимагає від медицини нових рішень для їх виявлення та лікування. З іншого боку, стрімкий розвиток технологій надає унікальні можливості для покращення діагностики та моніторингу цих захворювань. Такі технологічні прориви відкривають нові перспективи не тільки в ранньому виявленні нейродегенеративних змін, але й у розумінні механізмів їх розвитку та прогресування.

Розуміння нейродегенеративних захворювань як складних, багатофакторних станів вимагає інтеграції знань з різних галузей – від нейробиології до комп'ютерних наук. Ці захворювання можуть розвиватися під впливом різноманітних факторів, включаючи генетичну схильність, вікові зміни та зовнішнє середовище.

1.1 Нейродегенеративні захворювання, їх типи та причини виникнення

Нейродегенеративні захворювання – це клас повільно прогресуючих незворотних станів, що характеризуються загибеллю нейронів і подальшою атрофією певних ділянок мозку. Ці захворювання можуть мати значний вплив на різні частини головного мозку, що призводить до широкого спектру симптомів, залежно від того, які ділянки мозку зазнають дегенерації. Ці розлади переважно проявляються в літньому віці і включають хворобу Альцгеймера, хворобу Паркінсона, хворобу Хантінгтона, хворобу Піка, бічний аміотрофічний склероз, деменцію з тільцями Леві та інші подібні асоційовані стани [1]. Всі вони

характеризуються зниженням когнітивних здібностей, важкими руховими порушеннями, погіршенням соціального функціонування та значними труднощами у виконанні повсякденних завдань.

Наразі нейродегенеративні розлади невиліковні, а їх лікування спрямоване на сповільнення прогресування хвороби, покращення якості життя пацієнтів та полегшення симптомів. За останні десятиліття кількість людей з діагностованими нейродегенеративними розладами зростає. Це зростання переважно пов'язане зі збільшенням тривалості життя та підвищенням ефективності ранньої діагностики [2].

Нейродегенеративні захворювання відрізняються рядом характерних ознак, які визначають їх вплив на мозок та функції організму (рисунок 1.1).

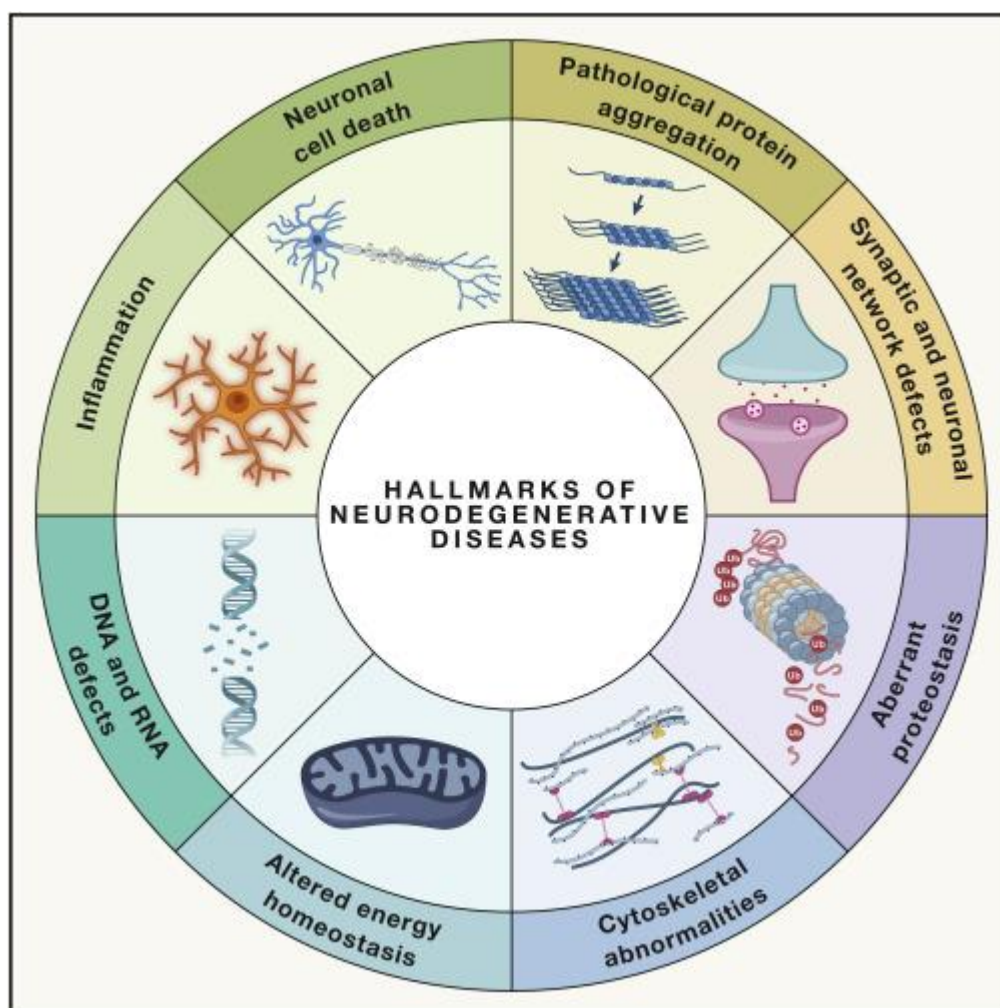


Рисунок 1.1 – Ознаки нейродегенеративних захворювань

Основоположними рисами таких станів є [3]:

– загибель нейронів: втрата нервових клітин є центральною проблемою при нейродегенеративних захворюваннях, ведучи до зменшення функціональності мозку та втрати ментальних та фізичних здібностей;

– патологічна агрегація білків: неправильне складання та накопичення білкових структур в мозку, таких як амілоїдні бляшки, є ключовим фактором у розвитку багатьох нейродегенеративних захворювань. Ці білкові агрегати можуть заважати нормальній роботі нейронів і сприяти їх загибелі;

– синаптична дисфункція: неправильна робота синапсів, через які нейрони комунікують між собою, веде до збоїв в нейронних мережах і може порушувати обробку інформації, когнітивні та рухові функції;

– деградація аксонів: ушкодження аксонів, довгих відростків нейронів, які передають сигнали на великі відстані, порушує нейротрансмісію та може спричинити нейродегенерацію;

– автофагія: цей клітинний процес забезпечує видалення пошкоджених білків та органел, і його порушення може сприяти накопиченню шкідливих компонентів у клітині;

– аномалії цитоскелету: зміни в структурі та функції цитоскелету нейронів можуть призводити до їх дисфункції та смерті;

– пошкодження ДНК та РНК: пошкодження цих молекул може порушити клітинне функціонування та призводити до генетичних змін, які поглиблюють дегенерацію нейронів;

– запалення: постійний запальний процес в мозку може підривати нормальне функціонування нейронів і підсилювати дегенеративні зміни, що особливо помітно в хронічному перебігу нейродегенеративних захворювань.

Найпоширеніші нейродегенеративні розлади спричинені білковими аномаліями і включають амілоїдозу (захворювання, при яких відбувається неправильне складання і накопичення амілоїдних білків у різних тканинах

та органах, включаючи мозок), та опатії (захворювання, пов'язані з патологічними змінами тау-білка, який є важливим компонентом нейронного цитоскелету) та синуклеїнопатії (захворювання, зумовлені агрегацією білка альфа-синуклеїну в нервових клітинах, що призводить до їхньої дисфункції та загибелі) [4].

Нейродегенеративні захворювання можна класифікувати за різними критеріями, включаючи основні патологічні процеси, клінічні симптоми та зони мозку, що найбільш уражені (рисунок 1.2).




Рисунок 1.2 – Ділянки мозку, які вражаються різними нейродегенеративними захворюваннями

До основної класифікації можна віднести [5]:

– хвороба Альцгеймера та інші форми деменції: нейродегенеративні стани, при яких відбувається поступова втрата когнітивних функцій та

пам'яті. Хвороба Альцгеймера є найбільш поширеною причиною деменції, яка характеризується амілоїдними відкладеннями та нейрофібрилярними клубочками в мозку, що призводить до загибелі нейронів, особливо в областях, відповідальних за пам'ять та мислення;

– хвороба Паркінсона та пов'язані з нею розлади: захворювання, які вражають рухову систему, провокуючи симптоми, такі як тремор, ригідність м'язів, повільність рухів та порушення постави та ходи. Хвороба Паркінсона пов'язана зі знищенням нейронів в області мозку, відомої як чорна субстанція, що веде до дефіциту нейромедіатора допаміну;

– пріонні захворювання: рідкісні інфекційні захворювання, які викликаються неправильно складеними білками (пріонами), що призводять до швидкого руйнування нервової тканини. Пріонні захворювання можуть мати спадковий характер або передаватися через інфіковані тканини та можуть проявлятися у вигляді швидкопрогресуючої деменції та неврологічних дисфункцій;

– хвороби моторних нейронів: група станів, що характеризуються прогресивним втратою моторних нейронів, які керують скороченням м'язів. Внаслідок цього відбувається слабкість м'язів, спастичність та, в кінцевому рахунку, параліч. Аміотрофічний бічний склероз (АБС) є одним з найвідоміших видів;

– хвороба Гентінгтона: генетично обумовлене нейродегенеративне захворювання, яке проявляється порушеннями рухових функцій, когнітивними розладами та змінами особистості. Характеризується агрегацією мутованого білка, що призводить до нейродегенерації, особливо в базальних гангліях;

– спинальна м'язова атрофія (СМА): генетичний розлад, що спричиняє прогресивну втрату моторних нейронів у спинному мозку, що призводить до зниження м'язової сили та атрофії. СМА впливає на фізичні здібності, такі як ходьба, їжа та дихання.

Причини виникнення нейродегенеративних захворювань можуть бути різноманітними та часто є комбінацією генетичних факторів, вікових змін та зовнішніх впливів, таких як отруєння токсинами або навіть повторні травми голови.

Незважаючи на інтенсивні дослідження, багато аспектів нейродегенеративних захворювань залишаються нез'ясованими, ускладнюючи пошук ефективних методів лікування та профілактики.

Діагностика нейродегенеративних захворювань значно просунулася за останні десятиліття, завдяки поєднанню клінічного огляду, нейровізуалізації, лабораторних тестів і нейропсихологічного оцінювання. Серед найбільш використовуваних методів нейровізуалізації – магнітно-резонансна томографія (МРТ), комп'ютерна томографія (КТ) та позитрон-емісійна томографія (ПЕТ), які дозволяють виявити структурні та функціональні зміни в мозку [6].

Інтеграція новітніх технологій, таких як штучний інтелект і машинне навчання, у процеси діагностики та лікування може значно підвищити точність виявлення захворювань на ранніх стадіях та ефективність терапевтичних втручань.

1.2 Огляд існуючих методів використання штучного інтелекту для аналізу МРТ-зображень

Магнітно-резонансна томографія – це високотехнологічний метод діагностики, який використовує сильні магнітні поля та радіохвилі для отримання деталізованих зображень внутрішніх структур організму. Він дозволяє візуалізувати м'які тканини, кістки та органи з високою роздільною здатністю, що робить МРТ незамінним у діагностуванні різноманітних захворювань, включаючи нейродегенеративні захворювання, пухлини, ураження суглобів та багато інших станів (рисунки 1.3).




Рисунок 1.3 – Зразки МРТ-зображень: А – нормальна МРТ; В – МРТ з гострим інсультом; С – МРТ з хворобою Альцгеймера; D – МРТ з пухлиною

У сучасній медичній практиці аналіз магнітно-резонансних томографій відіграє важливу роль у діагностиці нейродегенеративних захворювань. Штучний інтелект, і зокрема його підгалузі, такі як комп'ютерний зір, глибинне навчання та нейронні мережі, внесли значний вклад у цей процес. Комп'ютерний зір дозволяє системам ШІ «бачити» зображення МРТ, розпізнавати шаблони та визначати аномалії, що можуть свідчити про розвиток нейродегенеративного процесу.

Глибинне навчання, особливо з використанням конволюційних нейронних мереж, є особливо ефективним у роботі з великими наборами даних і виявленні складних візерунків у медичних зображеннях, що може бути неоціненним для раннього виявлення та моніторингу захворювань,

таких як хвороба Альцгеймера. Нейронні мережі можуть аналізувати МРТ на предмет змін в структурі та функціях мозку, що дозволяє виявляти зміни, які можуть залишатися непомітними для людського ока.

У 2007 році Н. Selvaraj та ін.[7] працювали над інтелектуальною методикою класифікації для виявлення нормальних і аномальних зрізів на даних магнітно-резонансної томографії головного мозку. Для виявлення пухлин та усунення людського фактору було розглянуто автоматизовану інтелектуальну систему класифікації, яка враховує важливість класифікації зрізів зображення при виявленні аномального об'єму МРТ.

Автори запропонували систему класифікації (рисунок 1.4) на основі LS-SVM, яка була випробувана на зрізах магнітно-резонансної томографії, та порівняли її з іншими класифікаторами, такими як SVM з лінійними та нелінійними ядрами радіально-базисних функцій, багат шаровий перцептрон та класифікатор К-найближчих сусідів. Результати показали, що підхід LS-SVM забезпечив кращу продуктивність порівняно з іншими класифікаторами.

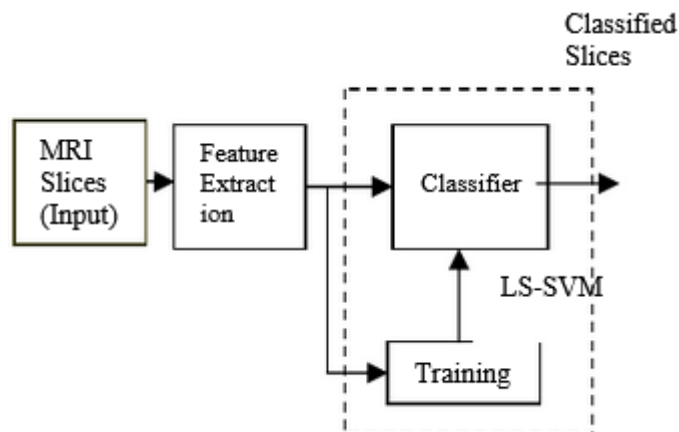


Рисунок 1.4 – Запропонована система

У 2011 році Y. Zhang та ін.[8] представили метод на основі нейронних мереж (НМ) для класифікації магнітно-резонансних зображень мозку як нормальних або аномальних. У цьому методі аналіз головних компонент

використовується для зменшення кількості ознак попередньо видобутих за допомогою вейвлет-перетворення. Зменшені ознаки потім надсилаються до нейронної мережі зворотного поширення, яка використовує масштабований спряжений градієнт (SCG) для знаходження оптимальних ваг нейронної мережі. У цій статті автори застосували цей метод на 66 зображеннях (18 нормальних, 48 аномальних). Розрахунковий час обчислень для одного зображення становив 0,0451 с, а досягнута точність класифікації була 100% як для навчальної, так і для тестової вибірки.

У 2015 році Muhammad Nazir та ін. [9] запропонували простий та інтелектуальний підхід до класифікації мозкових зображень МРТ. У своїй роботі вони використовували штучну нейронну мережу для класифікації зображень мозку МРТ як злоякісних або доброякісних. Дослідження складалося з трьох етапів: попередня обробка, екстракція ознак та класифікація. На етапі попередньої обробки застосовувалися фільтри для видалення шуму. Під час екстракції ознак з зображень МРТ вилучалися кольорові моменти як середні ознаки, які потім подавалися на просту пряму штучну нейронну мережу для класифікації. На рисунку 1.5 показано, як сіра шкала перетворюється на кольорову після виконання попередньої обробки.




Рисунок 1.5 – МРТ головного мозку до і після попередньої обробки

Метод було застосовано до 70 зображень, з яких 25 були нормальними, а 45 – аномальними. Точність класифікації склала 88,9% для навчальних даних, 94,9% для даних валідації та 94,2% для тестових даних, тоді як загальна точність спостерігалася на рівні 91,8%.

Основною перевагою запропонованого методу є його здатність ефективно обробляти зображення МРТ, видаляючи шум і виділяючи важливі ознаки для точної класифікації злоякісних та доброякісних уражень мозку.

У роботі [10] автори пропонують згорткову нейронну мережу для інтеграції всієї мультимодальної інформації, що міститься як в T1-зважених МР, так і в FDG-PET зображеннях області гіпокампа, для діагностики хвороби Альцгеймера. На відміну від традиційних алгоритмів машинного навчання, цей метод не вимагає ручного вилучення ознак, натомість він використовує ШНМ, що обробляють 3D-зображення, для вивчення ознак, необхідних для діагностики або прогнозування хвороби Альцгеймера.

Автори використовували дані з бази даних Alzheimer's Disease Neuroimaging Initiative (ADNI), щоб навчити класифікатори, які включають зображення пацієнтів із різними стадіями когнітивних порушень, включаючи стабільне та прогресуюче легке когнітивне ураження (sMCI та pMCI), та здорових контрольних осіб (CN), та отримали вищу точність 90,10% для завдання CN проти AD, 87,46% для завдання CN проти pMCI та 76,90% для завдання sMCI проти pMCI.

В роботі [11] автори запропонували глибоку згорткову нейронну мережу (CNN) для діагностики хвороби Альцгеймера на основі аналізу даних магнітно-резонансної томографії. Запропонована авторами мережа є ансамблем трьох глибоких згорткових нейронних мереж M1, M2, M3 з дещо відмінними конфігураціями. Запропонована модель показана на рисунку 1.6, де верхня мережа – це M1, середня мережа – M2, а нижня мережа – M3.




Рисунок 1.6 – Блок-схема запропонованої системи діагностики хвороби Альцгеймера

У 2018 році S. Basaia та ін. [12] розробили алгоритм глибокого навчання, який прогнозує хворобу Альцгеймера (AD) та легких когнітивних порушень, які перейдуть у хворобу Альцгеймера (с-MCI) на основі одного поперечного сканування структурної МРТ головного мозку. Згорткові нейронні мережі були застосовані до 3D T1-зважених зображень з бази даних ADNI (407 здорових контрольних осіб (HC), 418 з AD, 280 з с-MCI, 533 стабільних хворих на MCI [s-MCI]). МРТ-дані кожного набору даних для класифікації (AD vs HC, с-MCI vs HC, s-MCI vs HC, AD vs с-MCI, AD vs s-MCI, с-MCI vs s-MCI) були випадковим чином розділені на великий навчальний і валідаційний набір (90% зображень) і тестовий набір (10%

зображень). До зображень, відібраних для навчання та валідації, було застосовано аугментацію даних (рисунок 1.7). Ефективність CNN була протестована при розрізненні AD, с-MCI та s-MCI. Високі рівні точності були досягнуті в усіх класифікаціях, з найвищими показниками. CNNs розрізняли пацієнтів з с-MCI від пацієнтів з s-MCI з точністю до 75%.

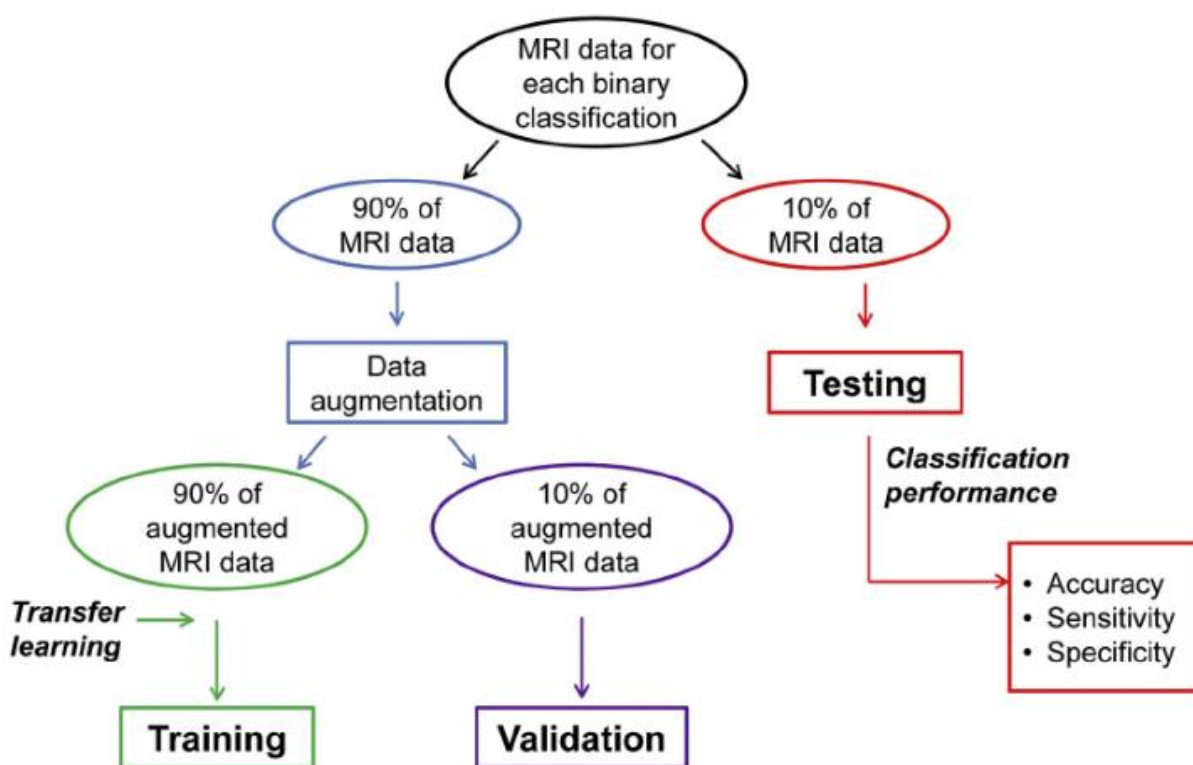


Рисунок 1.7 – Блок-схема основних етапів проведених експериментів

У своїй роботі [13] J. P. Kim та ін. дослідили застосування методів машинного навчання для ієрархічної класифікації фронтотемпоральної деменції (FTD) та хвороби Альцгеймера (AD) на основі даних про товщину кортикального шару мозку, отриманих з магнітно-резонансної томографії.

Дослідження включало 143 пацієнти з FTD, 50 пацієнти з деменцією, асоційованою з хворобою Альцгеймера, і 146 когнітивно нормальних суб'єктів. Автори виміряли товщину кори мозку за допомогою програмного забезпечення FreeSurfer та застосували оператор Лапласа-Бельтрамі для зменшення шуму в даних товщини кори, для класифікації тренували чотири

класифікатори за різними парами груп, здійснюючи ієрархічну класифікацію в чотири кроки: 1) когнітивно нормальні суб'єкти проти FTD + AD; 2) FTD проти AD; 3) поведінковий варіант FTD проти первинної прогресуючої афазії; 4) семантичний варіант PPA проти невиразного/аграматичного варіанту PPA. Застосовуючи 10-кратну перехресну валідацію, автори досягли точності класифікації всієї ієрархічної класифікації 75.8%, що було вище, ніж у неієрархічного класифікатора (73.0%).

Основним внеском цього дослідження є розробка автоматизованого класифікатора (рисунок 1.8), який успішно класифікує підтипи FTD, використовуючи лише дані про товщину кортикального шару.

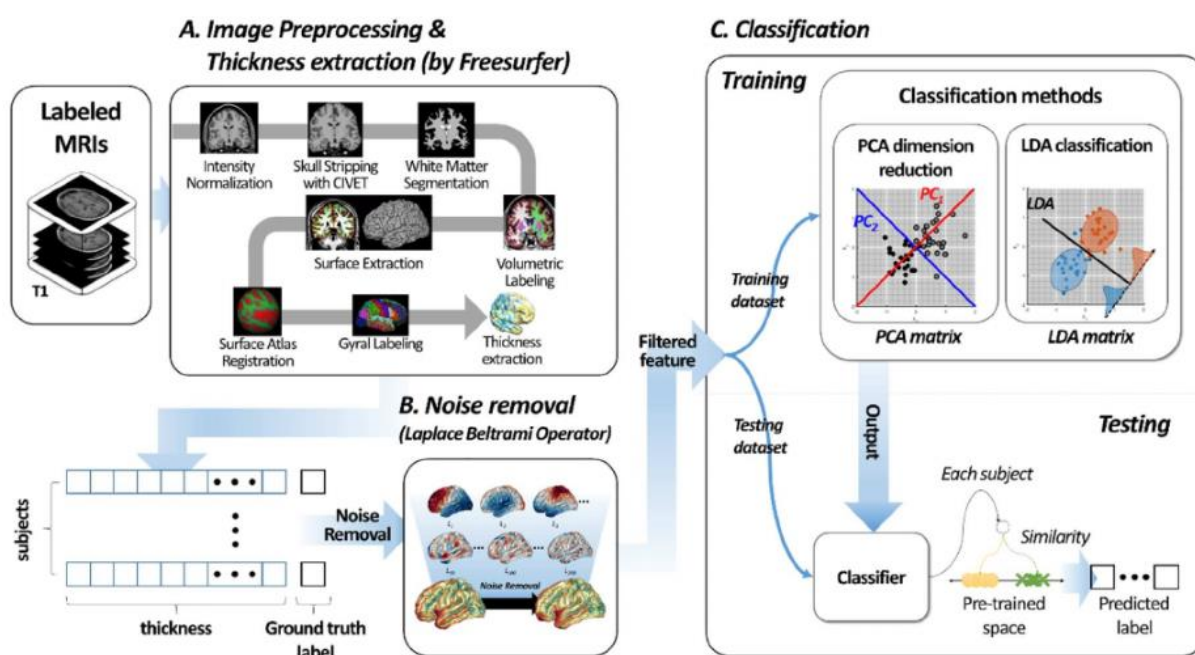


Рисунок 1.8 – Огляд запропонованого методу класифікації

J. Vouts та ін. у своїй роботі [14] визначали можливості застосування кількісної багатопараметричної МРТ-класифікації для виявлення легких когнітивних порушень (МСІ) в загальній неклінічній популяції. Для цього було створено моделі для виявлення хвороби Альцгеймера на різних

стадіях (легка та помірна), використовуючи анатомічні та дифузійні МРТ-показники, розраховані з клінічної популяції хворих на хворобу Альцгеймера, і потім застосовані до загальної популяції з 48 особами з МСІ і 617 особами з нормальним старінням. Ефективність моделей оцінювалася з використанням площі під кривою ROC (AUC) і порівнювалася з моделлю виявлення МСІ, навченою та застосованою до загальної популяції. Було виявлено, що моделі AD і mild-AD ідентифікували МСІ краще за випадковий рівень (AUC = 0.600; AUC = 0.619). Однак, модель moderate-AD не була здатною відрізнити МСІ від нормального старіння (AUC = 0.567). У загальній популяції моделі класифікації виявляли МСІ краще, ніж за випадковим принципом. Однак, показники ефективності класифікації були помірними і можуть бути недостатніми для надійного виявлення МСІ на основі МРТ у індивідуальному порядку.

У 2020 році D. Pan та ін. [15] запропонували новий підхід, який поєднує конволюційні нейронні мережі (CNN) з ансамбльовим навчанням для раннього виявлення хвороби Альцгеймера (AD) за допомогою магнітно-резонансної томографії. Цей підхід був спрямований на поліпшення точності та надійності виявлення AD, зокрема, ідентифікацію пацієнтів з легким когнітивним порушенням (МСІ), які мають високий ризик переходу до AD. Для досягнення цих цілей, дослідники використали дані з бази даних Alzheimer's Disease Neuroimaging Initiative (ADNI).

Застосування CNN дозволило автоматизувати процес вилучення ознак із зображень МРТ, що забезпечує ефективне та точне виявлення структурних змін у мозку, асоційованих з AD. Ансамбльове навчання, у свою чергу, сприяло підвищенню робастності і загальної точності системи шляхом інтеграції кількох моделей.

Основною перевагою запропонованого методу є його здатність не лише точно класифікувати AD проти здорового контролю (НС) та МСІс проти НС, але й ідентифікувати МСІс проти МСІ пацієнтів, що не переходять до AD (МСІnc), з високою точністю. Крім того, методологія

дозволила визначити специфічні мозкові регіони (рисунок 1.9), що вносять найбільший вклад у процес класифікації, що може допомогти у подальшому розумінні патогенезу AD та розробці цільових стратегій лікування та діагностики.

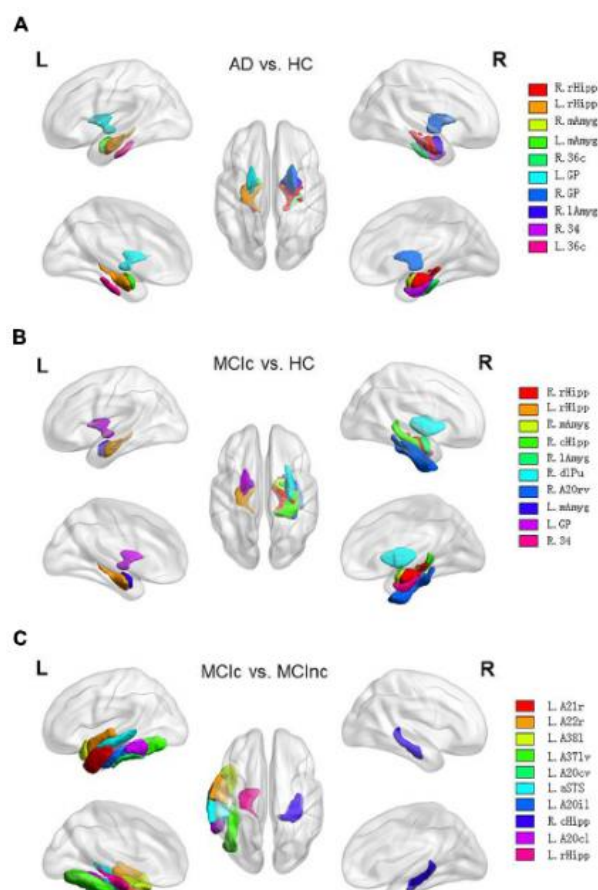


Рисунок 1.9 – Топ-10 найбільш розрізняваних ділянок мозку в кожній задачі бінарної класифікації

Точність та ефективність цих методів варіюються та залежать від багатьох факторів, включаючи якість зображень МРТ, різноманіття та обсяги навчальних даних, на яких було навчено систему, та їхню спроможність узагальнювати знання для нових даних. Виклики пов'язані з необхідністю забезпечення достатньої точності та надійності систем, що мають велике значення у клінічній практиці, де рішення, прийняті на основі аналізу ШІ, можуть мати великий вплив на лікування пацієнтів.

1.3 Постановка задачі дослідження

Виявлення та діагностика нейродегенеративних захворювань є складним завданням, оскільки багато симптомів можуть перетинатися з іншими захворюваннями, що вимагає використання точних інструментів діагностики та аналізу. Метою роботи є дослідження та оцінка потенціалу застосування методів штучного інтелекту для аналізу МРТ-зображень у діагностиці нейродегенеративних захворювань головного мозку.

Для досягнення поставленої мети необхідно виконати наступні задачі:

- дослідити актуальність обраної теми;
- ознайомитися з існуючими дослідженнями, присвяченими використанню методів штучного інтелекту в аналізі МРТ-зображень для діагностики нейродегенеративних захворювань, а також оцінити розвиток цієї галузі на сьогоднішній день;
- ознайомитися з методами обробки МРТ-зображень та дослідити алгоритми обробки та аналізу МРТ-зображень, такі як сегментація зображень та виділення ознак;
- розглянути сучасні методи штучного інтелекту, які використовуються для аналізу медичних зображень;
- розробити та навчити моделі, а також провести експерименти для оцінки розроблених моделей;
- проаналізувати результати та зробити висновки щодо ефективності розроблених моделей;
- сформулювати рекомендації щодо подальшого вдосконалення розроблених моделей.

2 МЕТОДИ ОБРОБКИ МРТ-ЗОБРАЖЕНЬ

Аналіз медичних зображень, зокрема магнітно-резонансних томографій, є важливою складовою діагностики нейродегенеративних захворювань. Висока складність та великий обсяг даних, які містяться у МРТ-зображеннях, вимагають застосування сучасних методів обробки та аналізу зображень для точного виявлення та оцінки патологічних змін у мозку.

2.1 Техніки передобробки зображень

Передобробка зображень є важливим етапом в аналізі МРТ-зображень, оскільки вона дозволяє підготувати дані для подальшої обробки та аналізу, зменшуючи вплив шумів та інших артефактів, а також покращуючи контрастність і гомогенність зображень. Від ефективності передобробки залежить успіх подальших етапів аналізу.

2.1.1 Фільтрація шумів

Фільтрація шумів є важливим етапом передобробки МРТ-зображень, оскільки вона дозволяє зменшити вплив небажаних сигналів, які можуть спотворювати зображення та ускладнювати подальший аналіз. Шуми можуть виникати через різні причини, такі як рух пацієнта під час сканування, електронні перешкоди або характеристики магнітного поля. Для ефективної фільтрації шумів використовуються різні методи, кожен з яких має свої переваги та недоліки. Вибір методу фільтрації залежить від типу шуму, вимог до збереження деталей зображення та обчислювальних ресурсів.

Існує два основні типи фільтрації, які широко використовуються – лінійна та нелінійна. Лінійні фільтри є базовими інструментами для

фільтрації шумів, які використовуються для згладжування зображень. Нелінійні фільтри застосовуються для обробки зображень з різними типами шумів і дозволяють зберегти контури та деталі зображення краще, ніж лінійні фільтри.

Лінійне згладжування застосовує середньозважене значення інтенсивностей сусідніх пікселів до кожного пікселя. Наприклад, для 3×3 маски середнє значення обчислюється як сума інтенсивностей всіх пікселів у масці, поділена на кількість пікселів. Така фільтрація усуває ті значення пікселів, які не схожі або не є репрезентативними для навколишніх пікселів [16].

Нехай $S_{x,y}$ представляє набір координат у прямокутному вікні підзображення розміром $a \times b$, з пікселем у центрі, позначеним через (x, y) :

$$f(x, y) = \frac{1}{ab} \sum_{(s,t) \in S_{x,y}} g(s, t). \quad (2.1)$$

Під час фільтрації обчислюється середнє значення пошкодженого зображення у прямокутній області, визначеній $S_{x,y}$. Значення відновленого зображення в будь-якій точці (x, y) – це просто середнє арифметичне, обчислене за пікселями в області, визначеній S .

Переваги: метод простий у реалізації та швидкий у виконанні.

Недоліки: розмиває контури та деталі зображення.

Фільтр Вінера є адаптивним методом, який мінімізує середньоквадратичну похибку між фільтрованим зображенням і оригіналом. Він ефективно зменшує шум, зберігаючи важливі деталі зображення (рисунок 2.1) [17]. Фільтр Вінера враховує локальну варіацію інтенсивностей пікселів, оцінюючи шум і корисний сигнал у кожному регіоні зображення. Фільтрація проводиться шляхом застосування оптимального вагового коефіцієнта до кожного пікселя.

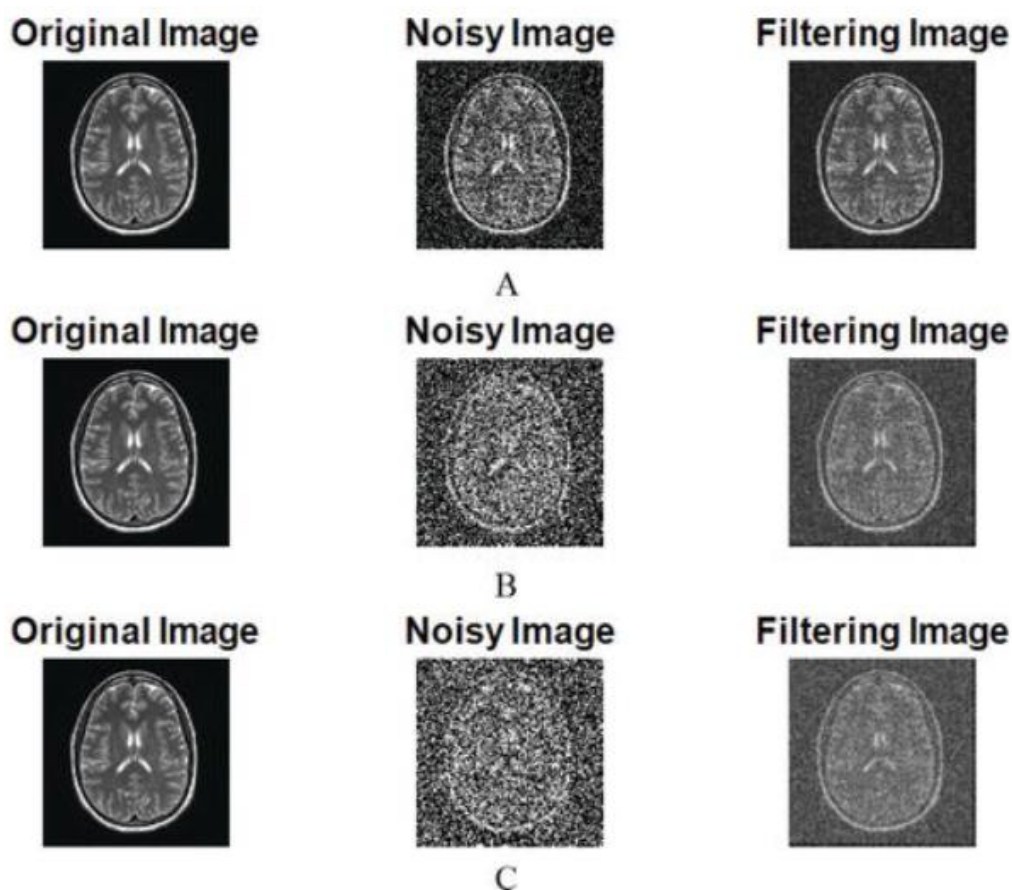


Рисунок 2.1 – Результат застосування фільтра Вінера

Переваги: ефективно видаляє шум, зберігаючи різкість контурів та деталі зображення.

Недоліки: більш складний у реалізації та вимагає більше обчислювальних ресурсів.

Медіанний фільтр є ефективним методом для видалення імпульсного шуму (рисунок 2.2). Для кожного пікселя зображення медіанний фільтр обчислює медіанне значення інтенсивностей сусідніх пікселів і замінює ним центральний піксель.

$$f(x, y) = \text{median}_{(u,v) \in K_{x,y}} \{g(u, v)\}, \quad (2.2)$$

де $K_{x,y}$ відповідає набором координат з центром у точці (x, y) , у прямокутному вікні підзображення, а median – медіанне значення вікна.

Переваги: ефективно видаляє імпульсний шум, зберігаючи при цьому різкість контурів, не розмиває зображення.

Недоліки: може бути менш ефективним для видалення інших типів шуму. Потребує більше обчислювальних ресурсів для великих зображень.

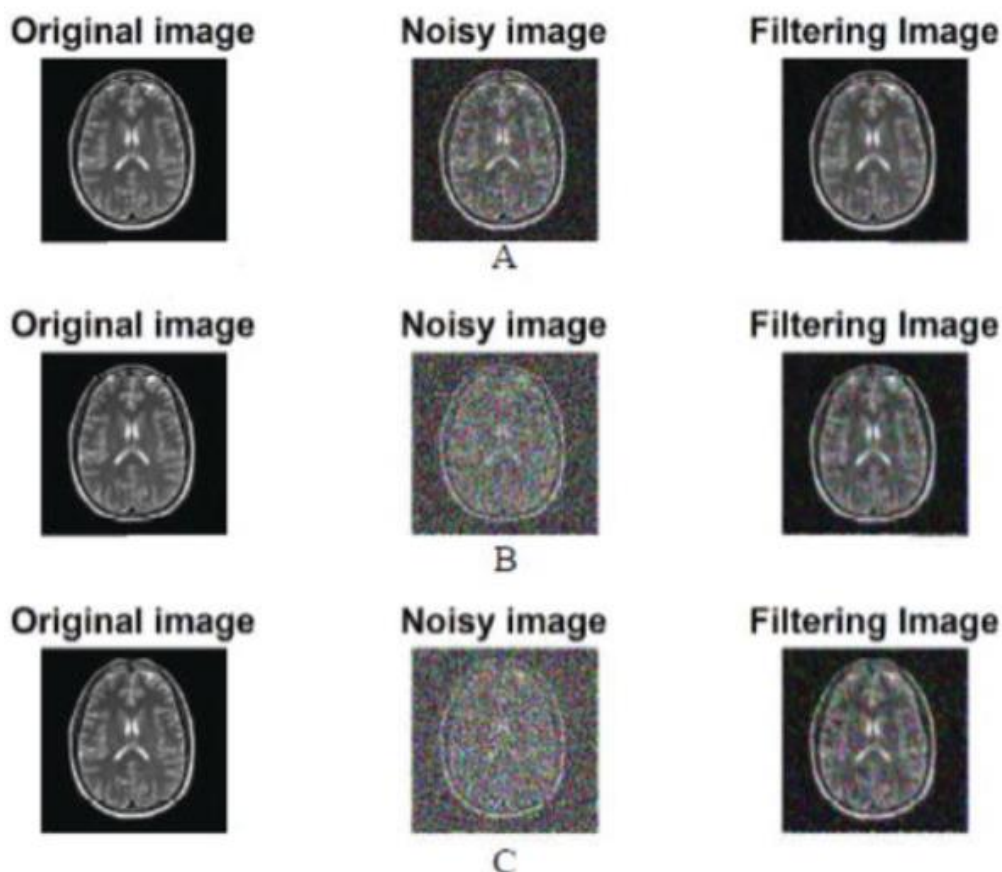


Рисунок 2.2 – Результат застосування медіанного фільтра

Анізотропний дифузійний фільтр зменшує шум, зберігаючи важливі контури за допомогою нелінійного процесу дифузії. Подібно до того, як молекули з різною температурою мають тенденцію обмінюватися теплом до досягнення однорідної температури, високочастотні зашумлені пікселі мають схильність до узгодження інтенсивності зі своїми локальними сусідами. У цьому випадку краї зображення подібні до буксируваних великих сусідніх об'ємів рідини з більшою ємністю, які потребують більше

часу для гомогенізації температури порівняно із зашумленими меншими об'ємами [18].

Переваги: зберігає контури і деталі зображення, одночасно зменшуючи шум.

Недоліки: складний у реалізації і потребує значних обчислювальних ресурсів.

Вейвлет-фільтрація використовує вейвлет-перетворення для декомпозиції зображення на різні частотні компоненти. Після цього виконується порогова обробка на кожному рівні декомпозиції, щоб видалити високочастотний шум [19].

Переваги: ефективно видаляє шум на різних масштабах, зберігаючи важливі деталі зображення, добре підходить для складних медичних зображень.

Недоліки: складний у реалізації та потребує більше обчислювальних ресурсів, потребує налаштування порогів для оптимальної фільтрації.

Результат застосування анізотропного дифузійного фільтра та вейвлет-фільтра наведено на рисунку 2.3 [20].




Рисунок 2.3 – Результат застосування анізотропного дифузійного фільтра та вейвлет-фільтра

Білатеральна фільтрація є гібридним методом, який поєднує просторове згладжування, враховуючи не тільки просторову близькість пікселів, але й схожість їх інтенсивностей. Це дозволяє зменшити шум, зберігаючи контури [21].

Переваги: ефективно зменшує шум, зберігаючи різкість контурів та дрібні деталі, добре підходить для зображень з високою контрастністю.

Недоліки: більш складний у реалізації та вимагає більше обчислювальних ресурсів, може бути повільним для великих зображень.




Рисунок 2.4 – Результат застосування білатеральної фільтрації

2.1.2 Корекція контрасту

Корекція контрасту є важливим етапом передобробки МРТ-зображень, оскільки вона дозволяє покращити видимість різних структур мозку. Вона забезпечує більш чітке розмежування між різними тканинами та патологічними утвореннями, що є критичним для точного аналізу та діагностики. Вибір методу корекції залежить від конкретних характеристик зображення та цілей аналізу.

Гістограмна рівномірність (Histogram Equalization, HE) є одним з найпоширеніших методів покращення контрасту зображень. Цей метод полягає в перетворенні гістограми інтенсивностей пікселів зображення таким чином, щоб вона стала більш рівномірною, розподіляючи інтенсивності більш рівномірно по всьому діапазону. Це збільшує контраст між сусідніми пікселями різної інтенсивності, що робить структури зображення більш виразними (рисунок 2.5).

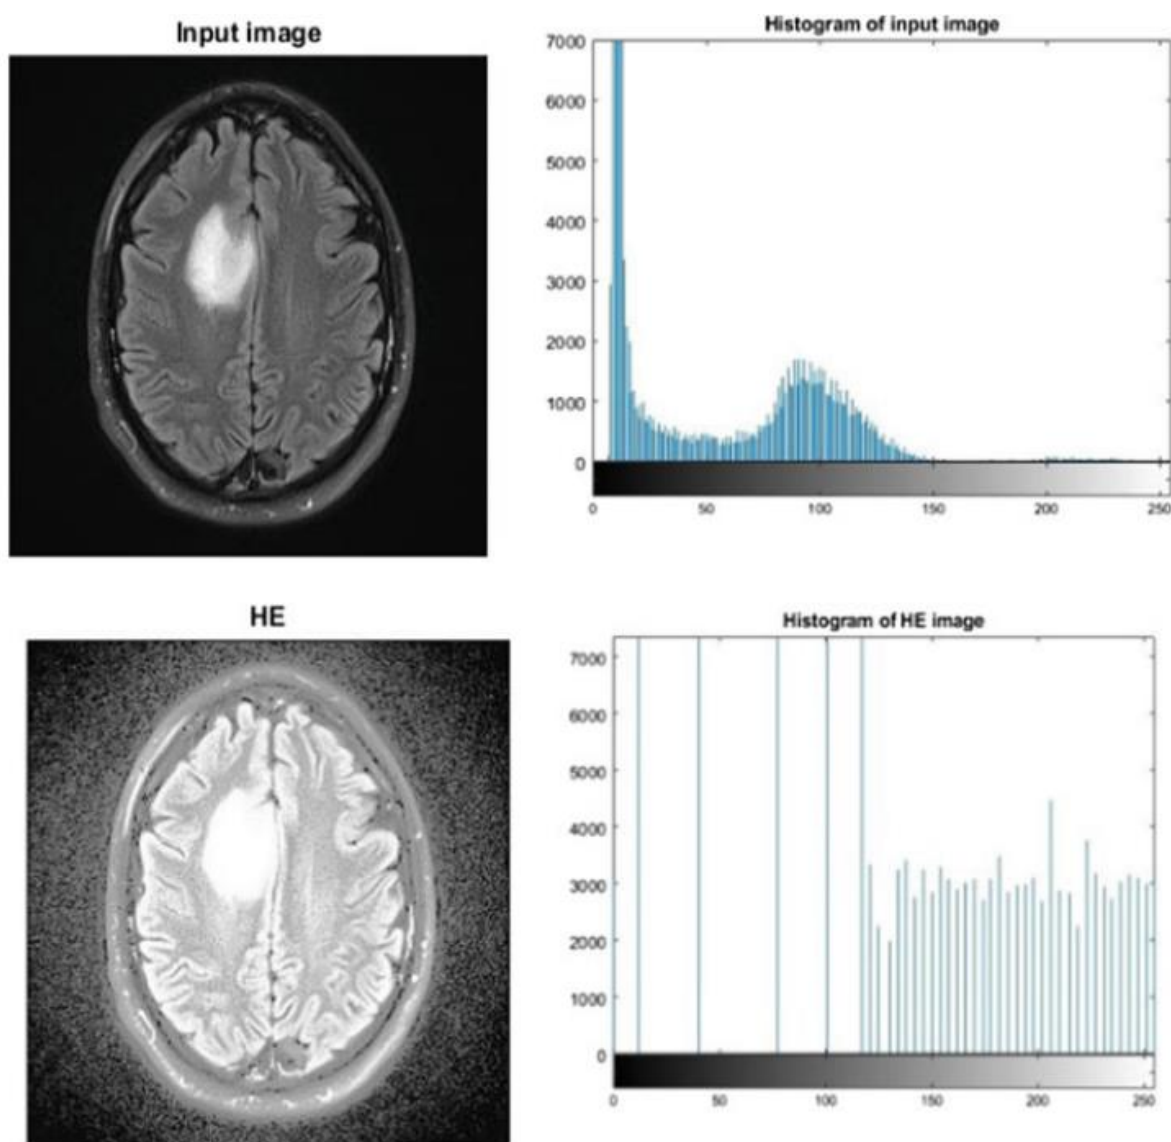


Рисунок 2.5 – Вирівнювання гістограми при пухлині головного мозку [22]

Формула розтягування гістограми зображення для збільшення контрастності вимагає знаходження мінімальної та максимальної інтенсивності пікселів, помножених на рівні сірого [23]:

$$g(x, y) = \frac{f(x, y) - f_{min}}{f_{max} - f_{min}} * 2^{bpp}. \quad (2.3)$$

Переваги: простий у реалізації, ефективно покращує загальний контраст зображення.

Недоліки: може призводити до перенасичення або недостатньої насиченості в окремих областях зображення, особливо при наявності великих областей з однаковою інтенсивністю.

Адаптивна гістограмна рівномірність (Adaptive Histogram Equalization, АНЕ) є розширенням методу НЕ, яке виконується на локальних зонах зображення. Це дозволяє покращити контрастність в областях з низькою та високою інтенсивністю одночасно. АНЕ поділяє зображення на невеликі блоки і виконує рівномірність гістограми в кожному блоці окремо. Потім результати поєднуються з урахуванням меж між блоками для запобігання артефактам [24].

Переваги: ефективно покращує контрастність у локальних зонах, зберігаючи деталі.

Недоліки: складніший у реалізації порівняно з рівномірністю гістограми, може створювати видимі межі між блоками при некоректному налаштуванні.

Адаптивна гістограмна рівномірність з обмеженням контрасту (Contrast Limited Adaptive Histogram Equalization, CLAHE) є вдосконаленням методу АНЕ, яке обмежує рівень контрасту, щоб уникнути артефактів кластеризації та надмірної насиченості в зображеннях з великою локальною контрастністю.

Переваги: запобігає надмірному посиленню шуму, зберігаючи природність контрасту, ефективно покращує контрастність у локальних зонах.

Недоліки: складний у реалізації, потребує підбору оптимального значення порогу контрасту для кожного зображення.

Логарифмічна та степенева корекція (степенева трансформація) використовують нелінійні перетворення для зміни інтенсивності пікселів, що дозволяє покращити контрастність у зображеннях з великим динамічним діапазоном [25].

Степенева корекція використовує степеневе перетворення для зміни інтенсивностей пікселів, що дозволяє налаштовувати контрастність у залежності від величини степеня. Інтенсивність кожного пікселя перетворюється за формулою:

$$P_k = (H_k)^\gamma, \quad (2.4)$$

де H_k – початкова інтенсивність;

P_k – перетворена інтенсивність;

γ – степеневий показник.

Переваги: гнучко налаштовується для покращення контрасту в різних діапазонах інтенсивностей.

Недоліки: потребує підбору оптимального значення степеневого показника для кожного зображення.

Логарифмічна корекція застосовує логарифмічне перетворення до інтенсивностей пікселів, зменшуючи контраст у світлих областях і збільшуючи його у темних. Інтенсивність кожного пікселя перетворюється за формулою:

$$Q_k = \beta \cdot \log(1 + P_k), \quad (2.5)$$

де P_k – початкова інтенсивність;

Q_k – перетворена інтенсивність;

β – постійний коефіцієнт, що знаходиться у діапазоні від 0 до 1 та обмежує надмірне підсилення та насичення.

Переваги: покращує видимість деталей у темних областях зображення.

Недоліки: може зменшити контраст у світлих областях.

На рисунку 2.6 наведено гістограму на різних рівнях обробки.




Рисунок 2.6 – Гістограма на різних рівнях обробки: а) вихідна гістограма, б) після степеневого перетворення, с) після логарифмічного перетворення

2.1.3 Нормалізація зображень

Нормалізація зображень є важливим етапом передобробки, який спрямований на вирівнювання яскравості та контрасту між різними зображеннями. Це дозволяє забезпечити їх сумісність для подальшого аналізу, зменшуючи вплив варіацій, спричинених умовами сканування або іншими факторами.

Мінімакс нормалізація (Min-Max Normalization) масштабує інтенсивності пікселів до певного діапазону, наприклад, від 0 до 1 або від 0 до 255. Це дозволяє вирівняти яскравість зображень, забезпечуючи їх порівнянність. Мінімакс нормалізація здійснюється за формулою:

$$I' = \frac{I - I_{min}}{I_{max} - I_{min}}, \quad (2.6)$$

де I – початкова інтенсивність;

I' – нормалізована інтенсивність;

I_{min} та I_{max} – мінімальне та максимальне значення інтенсивності відповідно.

Переваги: простота реалізації, забезпечує узгодженість інтенсивностей між різними зображеннями.

Недоліки: чутливість до екстремальних значень, які можуть суттєво вплинути на нормалізацію.

Z-нормалізація (Z-Score Normalization) зводить інтенсивності пікселів до стандартного нормального розподілу з середнім значенням 0 і стандартним відхиленням 1. Це дозволяє усунути варіації в яскравості, що можуть виникати через різні умови сканування. Z-нормалізація здійснюється за формулою:

$$I' = \frac{I - \mu}{\sigma}, \quad (2.7)$$

де I – початкова інтенсивність;

I' – нормалізована інтенсивність;

μ – середнє значення інтенсивностей;

σ – стандартне відхилення.

Переваги: усунення варіацій у яскравості, забезпечення порівнянності зображень незалежно від умов сканування.

Недоліки: потребує обчислення середнього значення та стандартного відхилення для кожного зображення.

Нормалізація за перцентилями (Percentile Normalization) вирівнює інтенсивності пікселів зображень, базуючись на їхньому перцентильному розподілі. Цей метод дозволяє забезпечити узгодженість між зображеннями, особливо коли існують значні варіації в яскравості та контрасті.

Переваги: забезпечує узгодженість розподілу інтенсивностей між різними зображеннями, зменшує вплив екстремальних значень.

Недоліки: може змінювати оригінальні інтенсивності зображень, що може призвести до втрати деяких особливостей.

На рисунку 2.7 наведено приклади застосування різних методів нормалізації до МРТ-зображень трьох суб'єктів (Subject D, Subject G, Subject H) [26].

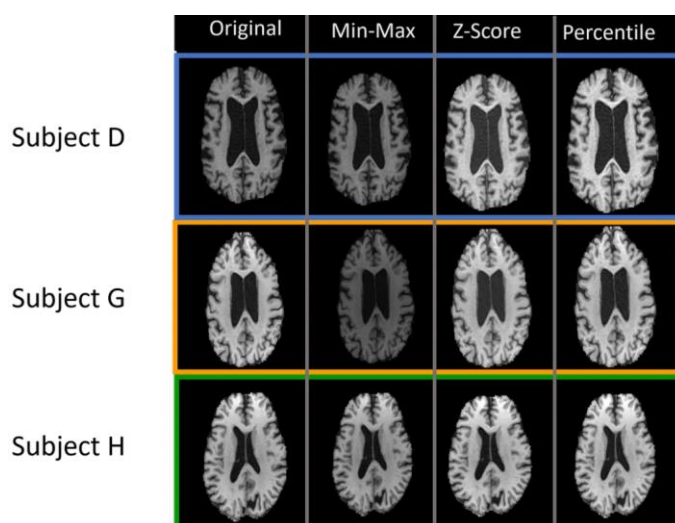


Рисунок 2.7 – Нормалізація МРТ-зображень

2.1.4 Вирівнювання гомогенності

Вирівнювання гомогенності є важливим етапом передобробки МРТ-зображень, спрямованим на корекцію неоднорідностей, які можуть виникати через нерівномірність магнітного поля або інші фактори. Ці неоднорідності можуть спотворювати зображення, ускладнюючи аналіз та діагностику.

Непараметричний алгоритм нормалізації нерівномірної інтенсивності (N3) є широко використовуваним методом нормалізації інтенсивності та видалення артефактів на МРТ-зображеннях. Корекція неоднорідності поля (N4 Bias Field Correction, N4ІТК) є вдосконаленим методом для корекції інтенсивності, спричиненої неоднорідністю магнітного поля. Він використовує ітеративний підхід для моделювання та корекції цього ефекту [27].

Метод N4ІТК визначає низькочастотний артефакт (похибкове поле) у зображенні та коригує інтенсивності пікселів, зменшуючи вплив цього артефакту.




Рисунок 2.8 – МРТ-зображення до та після N4ІТК

Переваги: ефективно коригує низькочастотні артефакти, покращуючи гомогенність зображення.

Недоліки: вимагає значних обчислювальних ресурсів та часу для ітеративного процесу.

Мультиспектральний підхід використовує кілька різних зображень одного і того ж об'єкта, отриманих при різних налаштуваннях магнітного поля, для оцінки та корекції неоднорідностей. При мультиспектральному підході відбувається об'єднання інформації з кількох зображень для оцінки неоднорідностей і подальшої корекції інтенсивностей пікселів.

Переваги: забезпечує точнішу корекцію неоднорідностей шляхом використання додаткової інформації.

Недоліки: вимагає проведення декількох сканувань, що може бути складним та часозатратним.

2.2 Алгоритми обробки та аналізу зображень

Основні алгоритми обробки та аналізу зображень включають сегментацію, виділення ознак, пошук контурів та аномалій. Сегментація дозволяє виділити окремі області мозку або патологічні утворення, що є критичним для точного діагностування. Виділення ознак допомагає отримати зображення, які використовуються для класифікації та діагностики, а методи пошуку контурів та аномалій дозволяють ідентифікувати та аналізувати патологічні зміни.

2.2.1 Сегментація зображень

Сегментація зображень є одним з найважливіших етапів обробки МРТ-зображень. Вона дозволяє розділити зображення на значущі частини або області, які відповідають різним анатомічним або патологічним структурам мозку. Це необхідно для точної ідентифікації та аналізу окремих

областей мозку. На рисунку 2.9 наведено основні методи сегментації, які використовуються для аналізу МРТ-зображень [28].

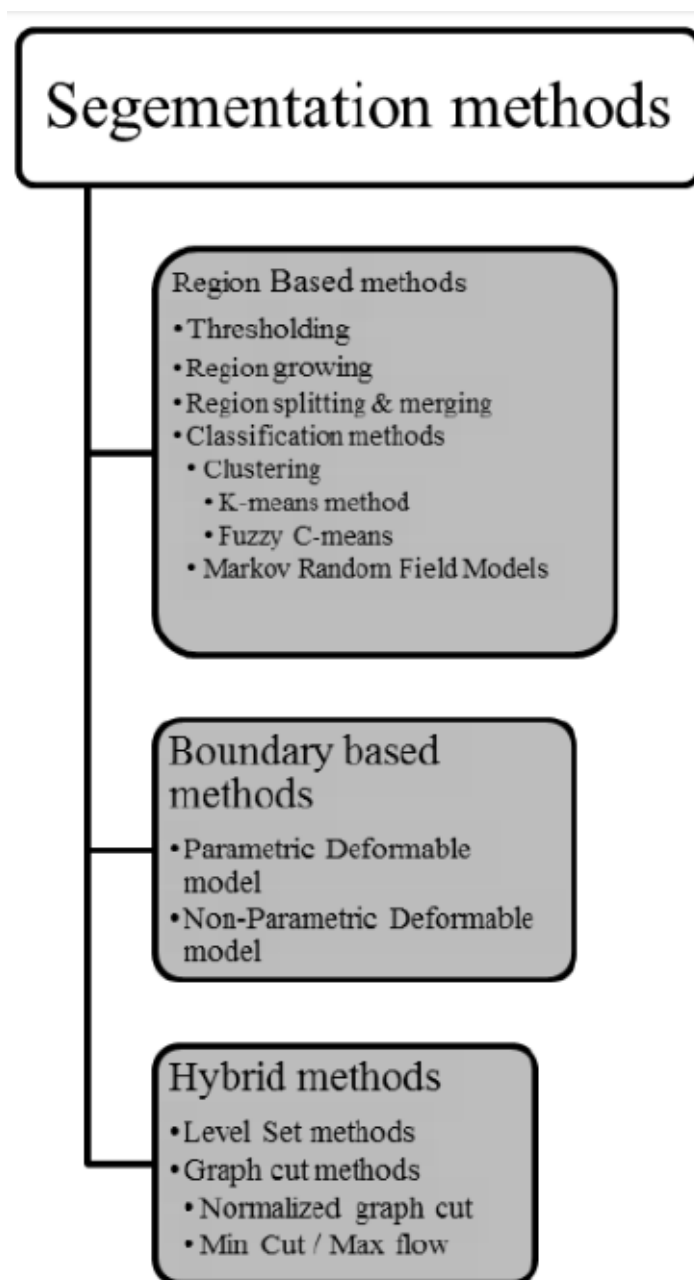


Рисунок 2.9 – Методи сегментації

Методи, засновані на області (Region-Based Methods) використовують інформацію про інтенсивності пікселів та їхнє розташування для формування однорідних областей.

Порогове розбиття (Thresholding) використовується для розділення зображення на області на основі інтенсивності пікселів. Поріг визначається таким чином, щоб виділити області, які мають інтенсивності вище або нижче заданого значення. Найпростіше бінарне порогове розбиття задається наступним чином:

$$S(x, y) = \begin{cases} 1, & \text{якщо } I(x, y) > T \\ 0, & \text{інакше} \end{cases}, \quad (2.8)$$

де T – порогове значення;

I – вхідне зображення;

S – вихідне зображення;

x та y – координати позиції.

Приклад МРТ-зображення мозку та його зображення з пороговим значенням ($T = 128$) показані на рисунку 2.10 [29].




Рисунок 2.10 – Порогове розбиття

Переваги: простота реалізації, швидкість обробки.

Недоліки: неефективність для зображень зі складними структурами або неоднорідними інтенсивностями.

Розширення областей (Region Growing) починається з початкової точки (seed point), яка задається або вручну, або автоматично, використовуючи попередні знання. Операція починається з початкової точки і з'єднує сусідні пікселі, які схожі на початкову точку за певними критеріями. Критеріями можуть бути, наприклад, інтенсивність пікселя, текстура у відтінках сірого або колір.

Час обчислення нарощування області з початковою точкою прямо пропорційний розміру сегментованої області в 3D об'ємі. Приклад МРТ-зображення мозку і виділення сірої речовини з різними ітераціями для початкової точки показані на рисунку 2.11.




Рисунок 2.11 – Розширення областей

Переваги: забезпечує точну сегментацію на основі локальних характеристик.

Недоліки: чутливість до вибору початкових точок, високі обчислювальні витрати для великих зображень.

Метод k -середніх (k -means) є одним з найпоширеніших алгоритмів кластеризації, який використовується для розділення набору даних на k груп (кластерів) на основі схожості їхніх властивостей. У контексті МРТ-зображень, цей метод дозволяє сегментувати зображення на різні області, що відповідають різним типам тканин або патологічним утворенням (рисунок 2.12).




Рисунок 2.12 – Сегментація методом K-means

Вибираються k початкових центроїдів кластерів, які можуть бути обрані випадково або за допомогою певної стратегії. Кожен піксель зображення призначається до найближчого центроїда на основі обраної метрики відстані (звичайно використовується евклідова відстань). Положення центроїда кожного кластера оновлюється як середнє значення інтенсивностей всіх пікселів, призначених до цього кластера. Кроки призначення пікселів і оновлення центроїдів повторюються до збіжності, тобто до тих пір, поки положення центроїдів не змінюється значно або досягнута задана кількість ітерацій [30].

Переваги: ефективність для сегментації областей з різними інтенсивностями.

Недоліки: необхідність визначення кількості кластерів заздалегідь, чутливість до початкової ініціалізації.

Метод нечітких c -середніх є розширенням методу k -середніх, який дозволяє кожному пікселю належати до декількох кластерів з певною ймовірністю. Це особливо корисно для сегментації МРТ-зображень, де межі між тканинами можуть бути нечіткими або неоднозначними.

Переваги: краще обробляє неоднорідні області.

Недоліки: вищі обчислювальні витрати.

2.2.2 Виділення ознак

Виділення ознак є процесом вилучення важливих характеристик зображення, які можуть бути використані для класифікації або діагностики. Ці ознаки можуть включати текстурні ознаки, ознаки форми, статистичні ознаки тощо. Виділення ознак дозволяє зменшити розмірність даних і сфокусувати увагу на найважливіших характеристиках, що сприяє покращенню точності алгоритмів аналізу зображень. Розглянемо основні методи виділення ознак.

Текстурні ознаки (Texture Features) використовуються для опису текстурних властивостей зображення, таких як однорідність, контраст, грубість тощо. Текстура є важливим аспектом у діагностиці, оскільки вона може містити інформацію про структуру тканин та наявність патологічних змін.

Метод співвідношення сірого рівня (Gray Level Co-occurrence Matrix, GLCM) використовує матрицю суміжності рівнів сірого для опису текстурних властивостей зображення. GLCM обчислює, як часто певні пари значень інтенсивностей пікселів (рівнів сірого) зустрічаються на певній відстані та напрямку один від одного в зображенні. Матриця складається з дванадцяти різних текстурних характеристик: середнє значення (Mean), дисперсія (Variance), середньоквадратичне відхилення (Standard Deviation),

корінь середньоквадратичного значення (RMS), енергія (Energy), ентропія (Entropy), гладкість (Smoothness), однорідність (Homogeneity), контраст (Contrast), кореляція (Correlation), куртозис (Kurtosis), асиметрія (Skewness) [31].

Рисунок 2.13 показує представлення GLCM для $d = 1$ та чотирьох орієнтацій (0° , 45° , 90° та 135°).

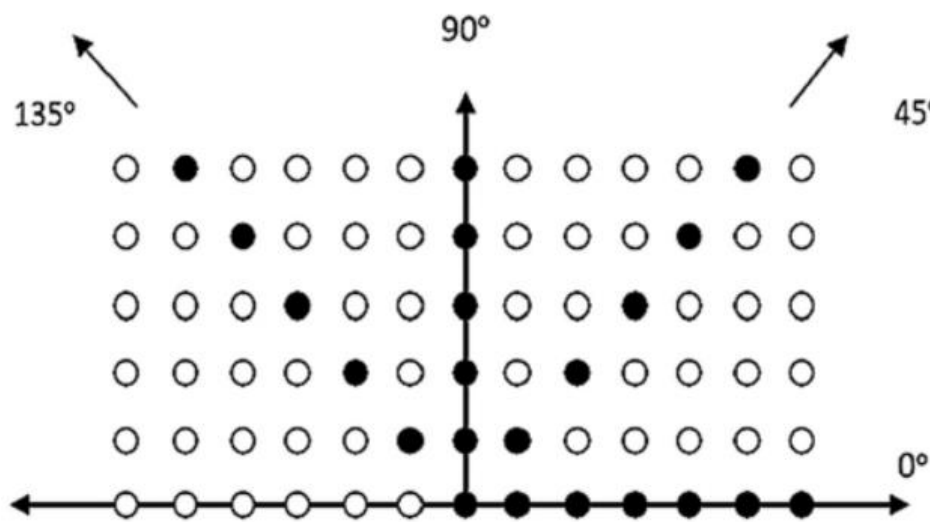


Рисунок 2.13 – Представлення GLCM

Переваги: забезпечує детальний опис текстури зображення, використовуючи статистичні показники, такі як контраст, ентропія, однорідність, енергія.

Недоліки: високі обчислювальні витрати для великих зображень, чутливість до змін у масштабі та обертанні.

Локальні бінарні патерни (Local Binary Patterns, LBP) використовуються для аналізу текстури шляхом кодування відносних інтенсивностей пікселів навколо кожного пікселя. LBP обчислює бінарний патерн для кожного пікселя, порівнюючи його інтенсивність з інтенсивностями сусідніх пікселів. Патерн формується на основі результатів порівняння (0 або 1), які потім об'єднуються в одне число (рисунок 2.14).




Рисунок 2.14 – Обчислення LBP

Переваги: стійкість до змін освітлення, простота реалізації, ефективність для опису текстури.

Недоліки: чутливість до шумів, втрата інформації про абсолютні значення інтенсивностей.

3 МЕТОДИ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ АНАЛІЗУ МРТ-ЗОБРАЖЕНЬ

Сучасні методи штучного інтелекту (ШІ) відіграють ключову роль у аналізі медичних зображень, зокрема МРТ-зображень мозку. Завдяки своїй здатності автоматично обробляти та аналізувати великі обсяги даних, алгоритми ШІ значно підвищують ефективність і точність діагностики нейродегенеративних захворювань. Використання ШІ дозволяє виявляти складні патерни, які можуть бути невидимі для людського ока, а також здійснювати класифікацію, сегментацію та виявлення аномалій на зображеннях з високою точністю.

3.1 Алгоритми машинного навчання для обробки медичних зображень

Алгоритми машинного навчання (МН) є потужними інструментами для аналізу медичних зображень, зокрема МРТ-зображень мозку. Основні алгоритми машинного навчання, такі як дерева рішень, рандомні ліси, лінійна та логістична регресія, метод опорних векторів, градієнтний бустинг та байєсові мережі, забезпечують різні підходи до обробки і аналізу медичних зображень. Дерева рішень використовуються для простого та інтуїтивно зрозумілого розподілу даних, метод опорних векторів забезпечує високу точність класифікації завдяки побудові оптимальних гіперплощин, а байєсові мережі дозволяють враховувати ймовірнісні взаємозв'язки між змінними.

3.1.1 Дерева рішень

Дерева рішень (Decision Trees, DT) – це непараметричний алгоритм навчання з вчителем, який застосовується для розв'язання задач класифікації та регресії. Цей алгоритм створює ієрархічну деревовидну

структуру, де кожен вузол представляє певний атрибут або рішення, а кінцеві вузли (листки) містять мітки класів або прогнозні значення (рисунок 3.1).

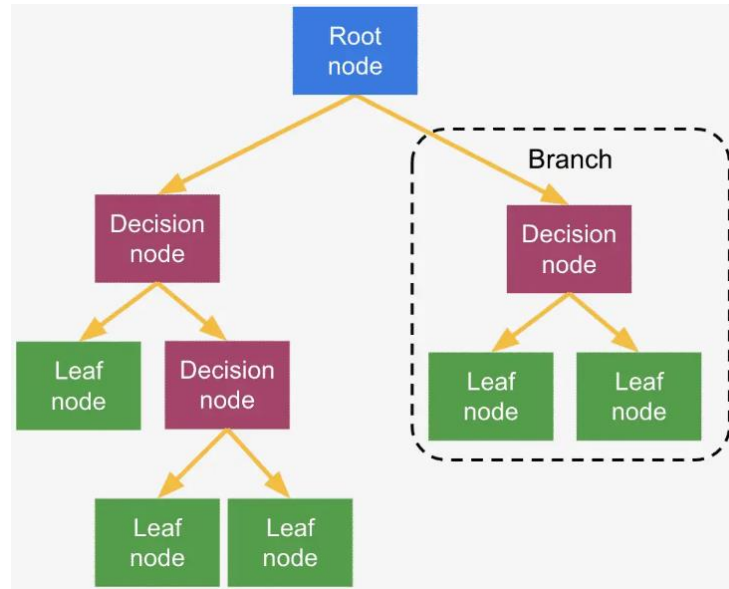


Рисунок 3.1 – Дерево рішень

Структура дерева рішень складається з наступних елементів [32]:

- кореневий вузол (root node): початковий вузол дерева, що містить усю популяцію або весь датасет. З нього починається процес класифікації чи регресії;

- вузли рішень (decision nodes): вузли, що утворюються при поділі кореневого вузла. Вони представляють проміжні рішення або умови;

- листкові вузли (leaf nodes): кінцеві точки дерева, де подальше розгалуження неможливе. Вони показують остаточний результат класифікації або регресії;

- гілка (branch): шляхи від одного вузла до іншого, що візуалізують різні варіанти рішень і їх наслідки;

- батьківський та дочірній вузли (parent and child node): батьківський вузол розгалужується на дочірні, представляючи конкретне рішення або умову, а дочірні ведуть до подальших рішень або результатів.

Процес побудови дерева рішень полягає в рекурсивному поділі тренувальних даних на підмножини залежно від значень атрибутів. На кожному кроці вибирається атрибут, який найкраще розділяє дані на класи, використовуючи метрики, такі як приріст інформації (Information Gain) або індекс Джині (Gini Index) [33].

Приріст інформації обчислюється як різниця між ентропією до та після розбиття:

$$IG(D_p, f) = I(D_p) - \sum_{j=1}^m \frac{N_j}{N} I(D_j), \quad (3.1)$$

де N – загальна кількість елементів;

N_j – кількість елементів у D_j ;

D_j – підмножина даних після розбиття;

I – ентропія;

D_p – початковий набір даних;

IG – приріст інформації.

Індекс Джині вимірює частоту неправильних класифікацій, якщо елементи були б класифіковані випадково:

$$Gini\ Index = 1 - \sum (p_i)^2, \quad (3.2)$$

де p_i – це відсоток елементів у наборі даних, що належать до i -ої категорії.

Одним з основних викликів при використанні дерев рішень є перенавчання (overfitting), коли дерево стає занадто складним і відображає шум даних замість узагальнених закономірностей. Для запобігання цьому застосовуються методи обрізки (pruning) дерева (рисунки 3.2) та встановлення максимальної глибини.




Рисунок 3.2 – Обрізка дерева

Обрізка дерева полягає у видаленні вузлів з невеликим приростом інформації або низьким значенням індексу Джині, що дозволяє зменшити складність моделі та підвищити її здатність до узагальнення.

Переваги:

- легко розуміються і візуалізуються, що робить їх зручними для інтерпретації результатів і пояснення прийнятих рішень;
- можуть працювати як з числовими, так і з категоріальними даними без необхідності в їх нормалізації або масштабуванні;
- можуть використовуватись для задач класифікації та регресії, а також для вирішення проблем з множинними класами.

Недоліки:

- можуть бути схильними до перенавчання, особливо коли дерево є дуже глибоким і має багато гілок. Це може призвести до низької узагальнюючої здатності на нових даних;
- невеликі зміни у даних можуть призвести до значних змін у структурі дерева рішень, що робить моделі менш стабільними;
- можуть мати обмежену здатність до моделювання дуже складних патернів без додаткових методів обробки.

Загалом, дерева рішень можуть бути ефективним методом для аналізу МРТ зображень при діагностуванні нейродегенеративних захворювань головного мозку завдяки їх прозорості та здатності працювати з різними

типами даних. Однак, для забезпечення точності та стабільності моделей необхідно застосовувати методи запобігання перенавчанню та оптимізації параметрів. Зважаючи на це, дерева рішень можуть бути інтегровані як частина комплексного підходу до діагностики, доповнюючи інші методи штучного інтелекту та підвищуючи точність і надійність діагностичних систем.

3.1.2 Метод опорних векторів

Метод опорних векторів (Support Vector Machines, SVM) є одним з найбільш ефективних і широко використовуваних алгоритмів машинного навчання для задач класифікації та регресії. Він базується на концепції знаходження оптимальної гіперплощини, що розділяє класи в просторі ознак.

SVM шукає гіперплощину, яка максимально розділяє класи у навчальному наборі даних, забезпечуючи максимальний зазор (маржу) між найближчими точками різних класів, що називаються опорними векторами (рисунок 3.3). Основна ідея полягає в тому, щоб знайти таку гіперплощину, яка мінімізує помилки класифікації [34].




Рисунок 3.3 – Метод опорних векторів

Лінійний SVM. Нехай ϵ навчальний набір даних (x_i, y_i) , де $x_i \in \mathbb{R}^n$ – це вектор ознак, а $y_i \in \{-1, 1\}$ – мітка класу. Гіперплощина визначається рівнянням:

$$w^T x + b = 0, \quad (3.3)$$

де w – вектор ваг;

b – зміщення.

Метою є знайти w і b , що максимізують маржу, яка визначається як відстань між гіперплощинами $w^T x + b = 1$ та $w^T x + b = -1$. Відстань між цими гіперплощинами становить $\frac{2}{\|w\|}$. Тому задача зводиться до мінімізації $\|w\|$ за умови, що всі точки правильно класифіковані $y_i(w^T x_i + b) \geq 1, \forall i$.

Це можна записати як задачу оптимізації:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \text{ за умови } y_i(w^T x_i + b) \geq 1, \forall i. \quad (3.4)$$

Ця задача є задачею квадратичного програмування, яку можна розв'язати за допомогою методів оптимізації.

У випадку, коли дані не є лінійно роздільними, SVM використовує ядра (kernel functions) для перетворення вхідного простору в простір більшої розмірності, де дані можуть бути лінійно роздільними. Ядра дозволяють обчислювати скалярні добутки у цьому просторі, не виконуючи явного перетворення.

Основні типи ядер:

– лінійне ядро:

$$K(x_i, x_j) = x_i^T x_j; \quad (3.5)$$

– поліноміальне ядро, де d – степінь многочлена, який необхідно вказати вручну:

$$K(x_i, x_j) = (x_i^T x_j + c)^d; \quad (3.6)$$

– радіально-базисне ядро (Gaussian RBF):

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2); \quad (3.7)$$

– сигмоїдне ядро, яке приймає вхідні дані та зіставляє їх зі значенням 0 та 1, щоб дані можна було розділити прямою лінією:

$$K(x_i, x_j) = \tanh(kx_i^T x_j + \theta). \quad (3.8)$$

Для нелінійних випадків використовується розширена задача оптимізації:

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \text{ за умови } y_i(w^T \phi(x_i) + b) \geq 1 - \xi_i, \quad (3.9)$$

$$\xi_i \geq 0, \quad \forall i,$$

де $\phi(x_i)$ – функція перетворення простору ознак;

ξ_i – змінні для штрафу за неправильну класифікацію;

C – гіперпараметр, що визначає компроміс між максимізацією маржі та мінімізацією помилок класифікації.

Метод опорних векторів (SVM) знаходить широке застосування в аналізі МРТ-зображень завдяки своїй здатності до високоточної класифікації та ефективному виявленню складних патернів у даних:

– використовується для аналізу текстурних особливостей мозкової тканини на МРТ-зображеннях, допомагаючи ідентифікувати регіони з відхиленнями від норми, які можуть вказувати на наявність патологій;

– застосовується для сегментації різних структур мозку, таких як сіра речовина, біла речовина та цереброспінальна рідина. Це дозволяє автоматично виділяти та аналізувати окремі області мозку;

– ефективно використовується для виявлення пухлин, аневризм та інших аномалій на МРТ-зображеннях, що є критично важливим для ранньої діагностики та лікування;

– використовується для аналізу послідовних МРТ-зображень з метою прогнозування прогресування нейродегенеративних захворювань, таких як розсіяний склероз або хвороба Альцгеймера.

Переваги:

– показує високу ефективність для задач класифікації, особливо на невеликих та середніх наборах даних;

– завдяки використанню ядер SVM може обробляти нелінійні взаємозв'язки в даних;

– ефективно працює з даними високої розмірності.

Недоліки:

– для великих наборів даних SVM може бути обчислювально затратним, особливо у випадку використання нелінійних ядер;

– підбір параметрів ядра та гіперпараметра C є критичним для досягнення хороших результатів, що може вимагати додаткових зусиль.

3.1.3 Байєсові мережі

Байєсові мережі (Bayesian Networks) є потужним інструментом машинного навчання, що використовує ймовірнісні графічні моделі для представлення та аналізу залежностей між змінними. Вони забезпечують спосіб моделювання складних взаємозв'язків у даних, що робить їх особливо корисними для аналізу медичних зображень, включаючи МРТ-зображення мозку.

Байєсові мережі складаються з орієнтованого ациклічного графа (рисунок 3.4), де вузли представляють змінні, а дуги вказують на умовні залежності між ними [35].




Рисунок 3.4 – Орієнтовний ациклічний граф

Кожен вузол має умовний розподіл ймовірностей, який визначає ймовірність вузла залежно від його батьківських вузлів. Таким чином, для кожного вузла X_i з батьками $Pa(X_i)$, умовний розподіл записується як $P(X_i|Pa(X_i))$. Повний спільний розподіл ймовірностей для всіх змінних у мережі можна представити як добуток умовних ймовірностей кожного вузла:

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i|Pa(X_i)). \quad (3.10)$$

Побудова байєсової мережі включає два основні етапи: структурне навчання та параметричне навчання. Структурне навчання полягає у визначенні графічної структури, що відображає залежності між змінними. Це може бути виконано вручну на основі експертного знання або

автоматично за допомогою алгоритмів, таких як алгоритм Чау-Лю (Chow-Liu) для побудови дерева залежностей. Параметричне навчання передбачає оцінку параметрів умовних розподілів ймовірностей для кожного вузла, зазвичай за допомогою методів максимального правдоподібності або байєсової оцінки.

Процес висновку в байєсових мережах включає обчислення апостеріорних ймовірностей для змінних на основі спостережуваних даних. Для цього використовуються різні методи, такі як алгоритм Белмана-Форда, марковське ланцюгове Монте-Карло (MCMC) та варіаційні методи.

Байєсові мережі широко застосовуються в медичній діагностиці та аналізі МРТ-зображень:

– можуть інтегрувати різні типи даних (клінічні, демографічні, генетичні) з інформацією, отриманою з МРТ-зображень, для діагностики нейродегенеративних захворювань, таких як хвороба Альцгеймера, Паркінсона та розсіяний склероз. Наприклад, мережа може моделювати залежність між об'ємом гіпокампа, віком пацієнта та генетичними маркерами для оцінки ризику розвитку хвороби Альцгеймера;

– за допомогою байєсових мереж можна прогнозувати, як буде змінюватися стан пацієнта з часом на основі послідовних МРТ-зображень. Наприклад, моделювання змін у товщині кори головного мозку може допомогти передбачити прогресування когнітивного спаду;

– можуть використовуватися для виявлення біомаркерів, що вказують на наявність або ризик розвитку певних захворювань. Аналізуючи залежності між різними ознаками, такими як текстурні характеристики тканин мозку та клінічні дані, можна виділити ключові маркери для ранньої діагностики;

– використовуються для автоматичної сегментації різних структур мозку на МРТ-зображеннях. Вони можуть поєднувати інформацію про інтенсивність сигналу, форму та анатомічні залежності для точного

виділення сірої речовини, білої речовини та інших структур. Це важливо для кількісного аналізу змін у мозку, пов'язаних із захворюваннями;

– дозволяють об'єднувати дані з різних модальностей (МРТ, ПЕТ, КТ) для покращення точності діагностики та аналізу. Наприклад, поєднання структурної інформації з МРТ та функціональної інформації з ПЕТ може дати більш повну картину стану мозку.

Переваги:

– байсові мережі дозволяють явно моделювати невизначеність і ймовірнісні взаємозв'язки між змінними;

– графічна структура мережі забезпечує візуальне представлення залежностей, що полегшує інтерпретацію моделі;

– можливість включення як спостережуваних, так і прихованих змінних, що дозволяє моделювати складні системи.

Недоліки:

– структурне навчання може бути обчислювально складним для великих наборів даних з багатьма змінними;

– якість моделі сильно залежить від якості та обсягу навчальних даних.

3.1.4 Рандомні ліси

Рандомні ліси (Random Forests) є потужним ансамблевим методом машинного навчання, який використовується для задач класифікації та регресії (рисунок 3.5). Вони складаються з великої кількості дерев рішень, що працюють разом для покращення точності та зменшення ризику перенавчання.

Принцип роботи рандомних лісів полягає у створенні множини дерев рішень, кожне з яких будується на основі різних випадкових підмножин даних та ознак. Кожне дерево робить своє передбачення, і результати всіх дерев об'єднуються для отримання фінального рішення шляхом

голосування (для класифікації) або усереднення (для регресії). Такий підхід дозволяє зменшити варіативність моделі та підвищити її стійкість до шуму в даних.




Рисунок 3.5 – Рандомні ліси

Рандомні ліси використовують метод бегінгу (bagging), або бутстрепінгу, для створення різних підмножин даних [36]. Це означає, що для кожного дерева вибирається випадкова підмножина навчальних даних з поверненням (тобто деякі зразки можуть повторюватися, а деякі можуть бути виключені). Крім того, для кожного розділення в дереві вибирається випадкова підмножина ознак, що сприяє додатковому зменшенню кореляції між деревами і, відповідно, покращенню загальної продуктивності ансамблю.

Переваги:

- рандомні ліси часто показують високу точність завдяки комбінуванню передбачень множини дерев рішень;
- використання випадкових підмножин даних та ознак знижує ризик перенавчання, особливо для великих і складних наборів даних;
- можуть ефективно обробляти великі обсяги даних з високою розмірністю;
- дозволяє оцінювати важливість ознак, що може бути корисним для розуміння ключових факторів, що впливають на передбачення.

Недоліки:

- навчання рандомних лісів може вимагати значних обчислювальних ресурсів, особливо для великих наборів даних;
- хоча окремі дерева рішень є інтуїтивно зрозумілими, рандомний ліс як ансамбль може бути складним для інтерпретації;
- вибір кількості дерев, глибини дерев та інших гіперпараметрів може вимагати значних зусиль для оптимізації моделі.

3.1.5 Лінійна регресія та логістична регресія

Лінійна регресія та логістична регресія (Linear Regression and Logistic Regression) є базовими, але важливими методами машинного навчання, що широко використовуються для аналізу даних (рисунок 3.6). Лінійна регресія застосовується для прогнозування числових значень, тоді як логістична регресія використовується для задач класифікації [37].




Рисунок 3.6 – Лінійна регресія та логістична регресія

Лінійна регресія моделює залежність між незалежними змінними (факторами) та залежною змінною (результатом) шляхом

підгонки лінії, що мінімізує суму квадратів відхилень спостережуваних значень від передбачених. Модель лінійної регресії має вигляд:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon, \quad (3.11)$$

де y – залежна змінна;

x_i – незалежні змінні;

β_i – коефіцієнти моделі;

ϵ – випадкова похибка.

Коефіцієнти моделі оцінюються методом найменших квадратів, який мінімізує суму квадратів залишків (різниць між спостережуваними та передбаченими значеннями):

$$\min_{\beta} \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_n x_{in}))^2. \quad (3.12)$$

Логістична регресія використовується для моделювання ймовірності належності спостереження до одного з двох класів. Вона є особливим випадком лінійної регресії, яка застосовується для бінарних залежних змінних. Модель логістичної регресії має вигляд:

$$P(Y = 1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}}, \quad (3.13)$$

де $P(Y = 1|X)$ – ймовірність того, що залежна змінна Y прийме значення 1 за даних значень незалежних змінних X .

Для оцінки коефіцієнтів моделі використовується метод максимального правдоподібності, який максимізує ймовірність спостережуваних даних:

$$\max_{\beta} \sum_{i=1}^n [y_i \log(P(Y = 1|X_i)) + (1 - y_i) \log(1 - P(Y = 1|X_i))]. \quad (3.14)$$

Лінійна регресія та логістична регресія, незважаючи на свою простоту, є потужними інструментами для аналізу МРТ-зображень. Вони забезпечують швидку та ефективну оцінку впливу різних факторів на медичні результати, допомагаючи лікарям у прийнятті обґрунтованих рішень щодо діагностики та лікування.

Застосування в аналізі МРТ-зображень:

- лінійна регресія може використовуватися для прогнозування обсягів уражень або змін у мозку на основі різних факторів, таких як вік, стать та інші клінічні дані;

- логістична регресія застосовується для класифікації наявності чи відсутності захворювань на основі аналізу МРТ-зображень та інших клінічних параметрів;

- обидва методи використовуються для аналізу взаємозв'язків між клінічними даними та характеристиками МРТ-зображень, що допомагає виявити важливі патерни та маркери захворювань;

- логістична регресія може бути використана для прогнозування ймовірності успішного лікування на основі початкових МРТ-зображень та інших факторів.

Переваги:

- прості у реалізації та інтерпретації;
- швидко навчаються, навіть на великих наборах даних;
- коефіцієнти моделі мають зрозуміле значення, що дозволяє інтерпретувати вплив кожної змінної на результат.

Недоліки:

- лінійна регресія припускає лінійну залежність між змінними, що може бути обмеженням для складних взаємозв'язків;

- логістична регресія може не впоратися зі складними, нелінійними взаємозв'язками між змінними;

- обидва методи можуть бути чутливими до високої кореляції між незалежними змінними.

3.1.6 Градієнтний бустинг

Градієнтний бустинг (Gradient Boosting) є одним із найефективніших методів ансамблевого навчання. XGBoost (Extreme Gradient Boosting) є популярною реалізацією цього методу, відомою своєю високою продуктивністю та точністю. XGBoost покращує продуктивність градієнтного бустингу завдяки ефективному використанню обчислювальних ресурсів, вбудованій регуляризації та підтримці паралельного обчислення.

Градієнтний бустинг працює за принципом послідовного навчання моделей, кожна з яких намагається виправити помилки своїх попередників. Основна ідея полягає в тому, щоб додавати нові моделі до ансамблю таким чином, щоб вони компенсували помилки попередніх моделей. Це досягається за допомогою градієнтного спуску, який мінімізує функцію втрат, вимірюючи різницю між фактичними значеннями та передбаченнями моделей [38].

На кожному етапі додається нове дерево $h_m(x)$, яке мінімізує залишкову помилку:

$$h_m(x) = \underset{h}{\operatorname{argmin}} \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + h(x_i)), \quad (3.15)$$

де $L(y, \hat{y})$ – функція втрат;

y_i – фактичне значення;

\hat{y} – передбачене значення;

$F_{m-1}(x_i)$ – ансамбль моделей до кроку m .

Остаточне передбачення оновлюється:

$$F_m(x) = F_{m-1}(x) + \alpha h_m(x), \quad (3.15)$$

де α – коефіцієнт навчання, що визначає вагу нового дерева.

Переваги XGBoost:

- висока точність завдяки послідовному вдосконаленню ансамблю моделей і використанню різних функцій втрат для різних задач;
- вбудовані механізми регуляризації дозволяють уникнути перенавчання моделі, зберігаючи її узагальнюючу здатність;
- оптимізований для швидкого навчання навіть на великих наборах даних завдяки паралельному обчисленню та використанню обмеженої пам'яті;
- підтримує різноманітні типи функцій втрат, що дозволяє адаптувати його до різних задач, включаючи класифікацію та регресію.

Недоліки:

- незважаючи на оптимізацію, навчання XGBoost все одно може бути ресурсомістким, особливо для великих наборів даних;
- підбір оптимальних гіперпараметрів, таких як кількість дерев, їх глибина та коефіцієнт навчання, може вимагати значних зусиль та часу;
- може бути чутливим до шуму в даних, що може впливати на точність передбачень, якщо дані не були попередньо очищені.

3.1.7 K-найближчих сусідів

Метод K-найближчих сусідів (K-Nearest Neighbors, KNN) є одним з найпростіших і найінтуїтивніших алгоритмів машинного навчання, який використовується для задач класифікації та регресії.

Метод KNN працює за простим принципом: для кожного нового зразка знаходиться k найближчих зразків у навчальному наборі даних за допомогою певної метрики відстані, зазвичай евклідової відстані. Клас новому зразку присвоюється на основі більшості класів серед найближчих сусідів (для задач класифікації) або усереднювання значень k найближчих сусідів (для задач регресії) [39].

Вибір метрики відстані є критично важливим для роботи KNN, оскільки він визначає, які сусіди є найближчими. Найбільш поширені метрики включають:

– евклідова відстань (Euclidean Distance) обчислює відстань між точками у просторі ознак:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}; \quad (3.16)$$

– манхеттенська відстань (Manhattan Distance) обчислює відстань як суму абсолютних різниць між координатами:

$$d(x, y) = \sum_{i=1}^n |x_i - y_i|; \quad (3.17)$$

– відстань Мінковського (Minkowski Distance) – узагальнення евклідової та манхеттенської відстаней, визначається як:

$$d(x, y) = (\sum_{i=1}^n |x_i - y_i|^p)^{1/p}, \quad (3.18)$$

де при $p = 2$ отримуємо евклідову відстань, а для $p = 1$ – манхеттенську.

KNN знаходить широке застосування в аналізі МРТ-зображень завдяки своїй простоті та здатності обробляти як структуровані, так і неструктуровані дані.

Переваги:

– легко зрозуміти та реалізувати, не потребує навчання моделі, оскільки всі обчислення виконуються під час передбачення;

– може використовуватися як для задач класифікації, так і для регресії;

– швидко адаптується до нових даних, оскільки всі зразки зберігаються в пам'яті.

Недоліки:

– може бути обчислювально затратним для великих наборів даних, оскільки для кожного нового зразка потрібно обчислювати відстань до всіх навчальних зразків;

– може бути чутливим до шумів у даних, особливо якщо значення k вибрано занадто малим.

3.2 Глибинне навчання та нейронні мережі

Глибинне навчання та нейронні мережі є важливими складовими сучасного штучного інтелекту, які революціонізували аналіз та обробку медичних зображень, включаючи МРТ-зображення головного мозку. Завдяки своїй здатності автоматично виділяти складні патерни з даних, нейронні мережі досягли значних успіхів у задачах класифікації, сегментації та виявлення аномалій. Глибинні нейронні мережі (Deep Neural Networks, DNN) складаються з великої кількості шарів, що дозволяє їм вивчати більш абстрактні ознаки даних у порівнянні з традиційними алгоритмами машинного навчання.

3.2.1 Згорткові нейронні мережі

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) є одним з найбільш потужних інструментів глибинного навчання для аналізу візуальних даних. Вони відрізняються від традиційних нейронних мереж своєю здатністю автоматично виділяти ознаки зображень через спеціалізовані шари, що дозволяє їм досягати високої точності у задачах класифікації, сегментації та виявлення аномалій.

Основною ідеєю CNN є використання згорткових (convolutional) шарів (рисунок 3.7), які застосовують фільтри (ядра) до вхідних зображень для виділення важливих патернів, таких як краї, текстури та інші характеристики [40].




Рисунок 3.7 – Архітектура CNN

Основні компоненти архітектури CNN включають:

- згорткові шари (Convolutional Layers) застосовують фільтри (ядра) до вхідних зображень, щоб виділити локальні ознаки, такі як краї, текстури і патерни. Кожен фільтр проходить через все зображення, створюючи карту ознак (feature map). Фільтри є матрицями невеликого розміру, які ковзають по всьому зображенню, здійснюючи операцію згортки;

- пулінгові шари (Pooling Layers) зменшують розмірність карти ознак, зберігаючи найважливішу інформацію. Це допомагає зменшити кількість параметрів і обчислювальну складність мережі. Найпоширеніші види пулінгу – максимальний пулінг (max pooling) і середній пулінг (average pooling). Максимальний пулінг зберігає найбільше значення з кожної області, тоді як середній пулінг обчислює середнє значення;

- повнозв'язні шари (Fully Connected Layers) з'єднують всі нейрони з попереднього шару з кожним нейроном наступного шару. Вони зазвичай розташовані в кінці мережі і використовуються для класифікації або регресії на основі виділених ознак. Повнозв'язні шари забезпечують глобальне з'єднання, об'єднуючи всі локальні ознаки, виділені попередніми шарами;

- функції активації (Activation Functions): нелінійні функції активації, такі як ReLU (Rectified Linear Unit), застосовуються після згорткових та повнозв'язних шарів, щоб додати нелінійність в модель, що дозволяє мережі

навчати складні патерни. ReLU функція активується, коли значення є позитивним, і повертає нуль для негативних значень, що допомагає запобігти проблемі зникнення градієнта.

Регуляризація є важливим аспектом у навчанні CNN для запобігання перенавчанню. Один із популярних методів регуляризації – дроп-аут (dropout), що випадковим чином вимикає частину нейронів під час навчання, тим самим покращуючи узагальнюючу здатність моделі.

У контексті аналізу МРТ-зображень використовуються різні архітектури CNN, кожна з яких має свої особливості і переваги:

- AlexNet є однією з перших глибоких нейронних мереж, яка здобула популярність після перемоги у змаганні ImageNet 2012. Вона складається з п'яти згорткових шарів, за якими слідує три повнозв'язні шари. AlexNet використовує великі фільтри і агресивний пулінг, що дозволяє виділяти складні ознаки зображень;

- Inception (або GoogLeNet) запровадила концепцію використання багатошляхових згорткових шарів в одному модулі, що дозволяє мережі одночасно вивчати різні рівні абстракції. Це підвищує ефективність моделі, зменшуючи кількість параметрів;

- Xception (Extreme Inception) розширює ідею Inception, використовуючи глибокі згортки з сепарабельними згортковими шарами. Це значно зменшує кількість параметрів і підвищує продуктивність моделі при аналізі складних зображень, таких як МРТ;

- MobileNetV2 є легкою архітектурою, спеціально розробленою для мобільних та вбудованих пристроїв. Вона використовує глибокі згорткові шари з низькою затримкою і високою ефективністю, що робить її придатною для застосування в умовах обмежених ресурсів;

- ResNet50 є однією з версій резидуальних нейронних мереж, яка запровадила концепцію залишкових блоків для вирішення проблеми зникнення градієнта у дуже глибоких мережах. ResNet50 складається з 50 шарів і відома своєю високою точністю в завданнях класифікації зображень;

– VGG16 є глибокою нейронною мережею, яка складається з 16 шарів. Вона відома своєю простою та послідовною архітектурою, що складається з чергування згорткових і пулінгових шарів. VGG16 широко використовується для задач класифікації та сегментації зображень.

3.2.2 Автокодувальники

Автокодувальники (Autoencoders) є типом нейронних мереж, що використовуються для некерованого навчання та виділення ознак з даних. Вони складаються з двох основних компонентів: кодера і декодера. Кодер перетворює вхідні дані у компактне внутрішнє представлення (кодування), а декодер відновлює дані з цього представлення (рисунок 3.8). Основна мета автокодувальників – навчитися стискати дані і відновлювати їх з мінімальними втратами.




Рисунок 3.8 – Архітектура автокодувальника

Архітектура автокодувальника включає кілька основних компонентів:

- вхідний шар (Input Layer) приймає вхідні дані, такі як пікселі зображення. Наприклад, для МРТ-зображень кожен піксель може бути окремим вхідним нейроном;

– кодер (Encoder) складається з кількох прихованих шарів, які поступово зменшують розмірність вхідних даних, стискаючи їх у компактне внутрішнє представлення. Кодер виділяє найбільш значущі ознаки з вхідних даних;

– латентний простір (Latent Space) – це внутрішнє представлення даних, створене кодером. Це стиснене, більш абстрактне представлення, яке містить основну інформацію про вхідні дані;

– декодер (Decoder) складається з кількох прихованих шарів, які поступово збільшують розмірність даних з латентного простору, відновлюючи їх до вихідних даних. Декодер намагається реконструювати вхідні дані з латентного представлення;

– вихідний шар (Output Layer) генерує кінцевий результат, який має бути максимально схожим на вхідні дані.

Існує кілька варіантів автокодувальників, які використовуються для різних задач [41]:

– шумознижувальні автокодувальники (Denoising Autoencoders): цей тип автокодувальника навчається відновлювати чисті дані з зашумлених вхідних даних. Він додає шум до вхідних даних і навчається реконструювати оригінальні дані без шуму, що робить його корисним для зменшення шумів у зображеннях;

– розріджені автокодувальники (Sparse Autoencoders): цей тип автокодувальника використовує регуляризацію, щоб забезпечити розрідженість латентного представлення. Він намагається зробити так, щоб більшість нейронів у латентному просторі були неактивні, що сприяє виділенню найбільш значущих ознак;

– варіаційні автокодувальники (Variational Autoencoders): використовують імовірнісний підхід до кодування даних. Вони навчаються не тільки відновлювати дані, але і генерувати нові зразки, подібні до навчальних даних. Це досягається за рахунок введення випадкових змінних у латентний простір;

– згорткові автокодувальники (Convolutional Autoencoders) використовують згорткові нейронні мережі (CNN) як будівельні блоки. Кодер складається з декількох шарів, які приймають зображення або сітку як вхідні дані і пропускають їх через різні шари згортки, формуючи таким чином стиснене представлення вхідних даних. Декодер є дзеркальним відображенням кодера, він деконволює стиснене представлення і намагається відновити оригінальне зображення.

3.2.3 Рекурентні нейронні мережі

Рекурентні нейронні мережі (Recurrent Neural Networks, RNN) є типом нейронних мереж, які спеціально розроблені для обробки послідовних даних і врахування часових залежностей. На відміну від звичайних нейронних мереж, RNN мають рекурентні зв'язки, що дозволяють їм зберігати інформацію про попередні кроки і використовувати її для передбачення наступних значень. Це робить їх особливо корисними для задач, де порядок і контекст даних є важливими, таких як аналіз часових рядів, текстів або послідовностей зображень.

Основна архітектура RNN включає рекурентний шар, де нейрони мають зворотні зв'язки, що дозволяють зберігати інформацію про попередні кроки. У типовій RNN на кожному кроці часу обчислюється поточний стан нейрона на основі вхідних даних і попереднього стану (рисунок 3.9).




Рисунок 3.9 – Архітектура RNN

Навчання RNN відбувається шляхом мінімізації різниці між передбаченими значеннями і фактичними мітками на кожному кроці часу. Основні етапи навчання включають:

- прямий прохід (Forward Pass): вхідні дані проходять через всі шари мережі на кожному кроці часу, на виході отримуючи передбачені значення. Кожен нейрон прихованого шару отримує вхід від вхідного шару та від свого попереднього стану;

- обчислення функції втрат (Loss Calculation): функція втрат вимірює різницю між передбаченими значеннями і фактичними мітками на кожному кроці часу. Найпоширеніші функції втрат включають середньоквадратичну помилку (Mean Squared Error, MSE) і крос-ентропію (Cross-Entropy);

- зворотний прохід у часі (Backpropagation Through Time, BPTT): градієнти функції втрат обчислюються від останнього кроку часу до першого, оновлюючи ваги нейронів на кожному кроці (рисунок 3.10). Це дозволяє враховувати вплив кожного попереднього стану на поточний вихід;

- оновлення ваг (Weight Update): ваги нейронів оновлюються за допомогою алгоритму оптимізації, такого як градієнтний спуск (Gradient Descent) або його варіанти (наприклад, Adam).

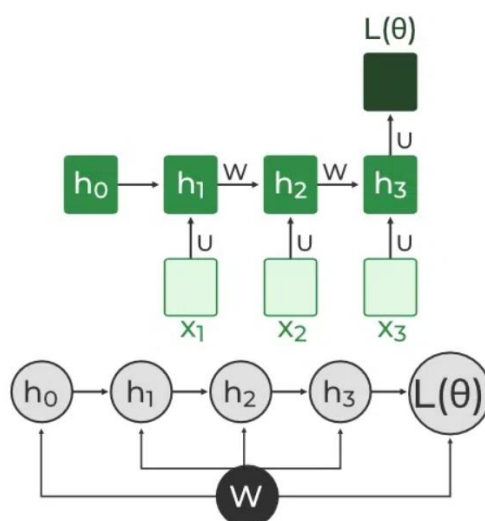


Рисунок 3.10 – Backpropagation Through Time

Традиційні RNN мають обмеження, пов'язані з проблемами зникнення і вибуху градієнтів, що ускладнює навчання довготривалих залежностей [42]. Для вирішення цих проблем були розроблені вдосконалені архітектури, такі як:

– довготривала короткочасна пам'ять (Long Short-Term Memory, LSTM): включає спеціальні блоки пам'яті, які дозволяють зберігати і передавати інформацію на довгі відстані. LSTM використовують три основні компоненти: вхідний, вихідний і забуттєвий (forget) гейти, що регулюють потік інформації (рисунок 3.11). Вхідний гейт контролює, яка нова інформація буде збережена в блок пам'яті. Забуттєвий гейт визначає, яка частина старої інформації буде стерта. Вихідний гейт контролює вихідну інформацію з блоку пам'яті. Така структура дозволяє LSTM ефективно вирішувати проблему зникнення градієнтів, зберігаючи важливу інформацію протягом тривалих періодів часу [43];




Рисунок 3.11 – Long Short-Term Memory

– рекурентні блоки зменшеної обчислювальної складності (Gated Recurrent Units, GRU): спрощена версія LSTM, яка об'єднує вхідний і забуттєвий гейти в один (рисунок 3.12). Це зменшує обчислювальну

складність і покращує ефективність навчання, зберігаючи при цьому здатність моделі обробляти довготривалі залежності. GRU використовує два гейти: оновлюючий гейт, який визначає, скільки нової інформації буде додано до поточного стану, і гейт скидання, який визначає, скільки старої інформації буде стерто. Завдяки цим механізмам GRU може навчатися швидше і з меншою обчислювальною вартістю порівняно з LSTM.

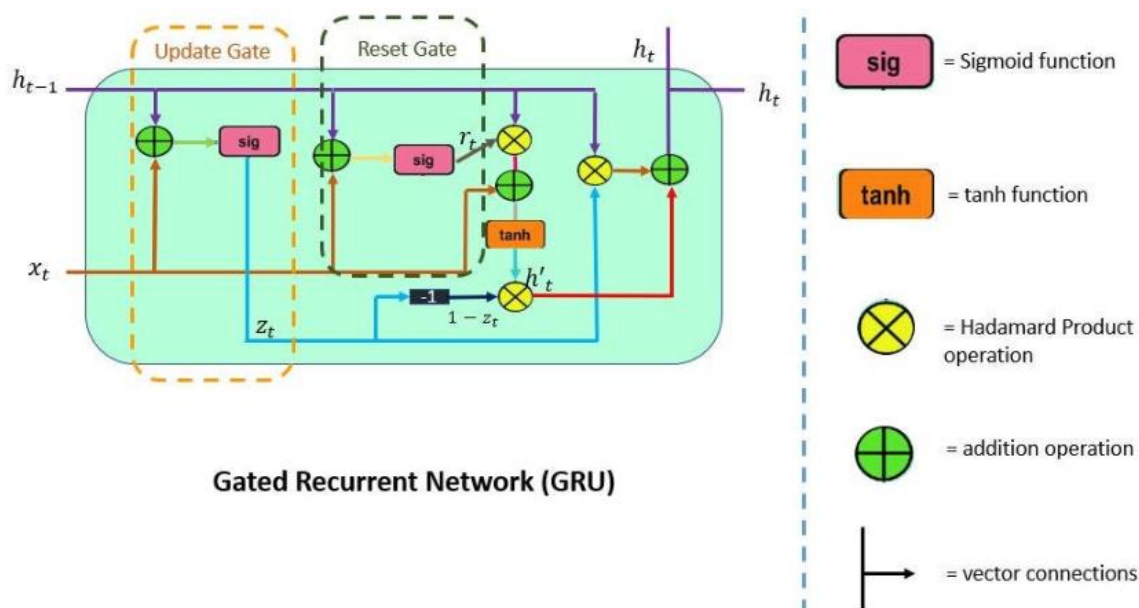


Рисунок 3.12 – Gated Recurrent Units

Рекурентні нейронні мережі (RNN) знайшли своє застосування в аналізі МРТ-зображень, особливо коли мова йде про послідовні або часові дані. Наприклад, RNN можуть бути використані для аналізу серій МРТ-зображень, знятих у різні моменти часу, щоб виявити динамічні зміни в структурі або функції мозку.

Також RNN використовуються для автоматичного сегментування МРТ-зображень, коли необхідно враховувати контекст сусідніх зрізів. Це дозволяє поліпшити точність сегментації, оскільки інформація з попередніх і наступних зрізів допомагає точніше визначити межі структур мозку.

3.3 Порівняння методів штучного інтелекту для аналізу медичних зображень

Різні методи машинного навчання та глибинного навчання мають свої сильні та слабкі сторони, які роблять їх більш або менш придатними для різних задач. Для визначення найбільш ефективних методів аналізу МРТ-зображень у діагностиці нейродегенеративних захворювань було проведено порівняння різних алгоритмів машинного навчання та глибинного навчання. Результати порівняння наведені у таблиці 3.1.

Таблиця 3.1 – Порівняння методів

Метод	Сильні сторони	Слабкі сторони
Дерева рішень (Decision Trees)	Простота візуалізації та інтерпретації, швидкість роботи на малих обсягах даних	Схильність до перенавчання, особливо на складних наборах даних
Метод опорних векторів (SVM)	Висока ефективність на малих та середніх наборах даних, добра здатність до класифікації	Вимогливість до обчислювальних ресурсів на великих наборах даних, складність вибору правильного ядра
Байєсові мережі (Bayesian Networks)	Добре працюють з неповними даними, можливість моделювання складних залежностей	Складність побудови та налаштування мереж, обмежена масштабованість
Рандомні ліси (Random Forests)	Висока точність, стійкість до перенавчання, можливість працювати з великими наборами даних	Складність інтерпретації результатів, вимогливість до обчислювальних ресурсів
Лінійна та логістична регресія	Простота реалізації та інтерпретації, швидкість роботи	Обмежена здатність до моделювання нелінійних залежностей, вимогливість до якості вхідних даних
Гradientний бустинг (XGBoost)	Висока точність, ефективність на складних задачах	Висока вимогливість до обчислювальних ресурсів, складність налаштування гіперпараметрів
К-найближчих сусідів (KNN)	Простота реалізації, відсутність припущень про розподіл даних	Низька ефективність на великих наборах даних, висока обчислювальна складність при великих обсягах даних

Продовження таблиці 3.1

Згорткові нейронні мережі (CNN)	Висока ефективність для аналізу зображень, здатність виявляти складні патерни	Вимогливість до великих обсягів даних та обчислювальних ресурсів, складність налаштування
Автокодувальники (Autoencoders)	Здатність до навчання без нагляду, ефективність у виявленні аномалій	Обмежена здатність до класифікації, складність налаштування
Рекурентні нейронні мережі (RNN)	Добре працюють з послідовними даними, здатність враховувати тимчасові залежності	Висока вимогливість до обчислювальних ресурсів, складність навчання (проблема зникаючих градієнтів)

Для аналізу МРТ-зображень найбільш ефективними виявилися згорткові нейронні мережі (CNN), завдяки їх здатності виявляти складні патерни та високій точності класифікації. Огляд сучасних досліджень показав, що CNN показують високу ефективність у цій галузі. Наприклад, у роботі [44], було виявлено, що CNN забезпечують точність понад 99% у класифікації різних стадій хвороби Альцгеймера. Інше дослідження [45] продемонструвало, що використання CNN для аналізу МРТ-зображень може значно покращити раннє виявлення паркінсонізму.

Інші методи, такі як метод опорних векторів (SVM) та рандомні ліси (Random Forests), також показують високу ефективність, особливо на малих та середніх наборах даних. Вони є менш вимогливими до обчислювальних ресурсів порівняно з CNN, але можуть поступатися у здатності виявляти складні нелінійні залежності у великих наборах даних.

Методи, як-от автокодувальники та рекурентні нейронні мережі (RNN), мають свої специфічні застосування. Автокодувальники добре підходять для задач виявлення аномалій та навчання без нагляду, тоді як RNN є ефективними для роботи з послідовними даними, хоча їх застосування для аналізу МРТ-зображень є обмеженим.

Таким чином, сучасні дослідження підтверджують, що CNN є найкращим вибором для аналізу МРТ-зображень завдяки їхній високій

точності та здатності виявляти складні візуальні патерни, що робить їх незамінними у діагностиці нейродегенеративних захворювань.

3.4 Метрики оцінки ефективності

Оцінка ефективності моделей машинного навчання та глибинного навчання є критично важливою для забезпечення надійності та точності їх роботи, особливо у контексті аналізу медичних зображень, таких як МРТ. Існує кілька метрик, які використовуються для оцінки продуктивності моделей, кожна з яких має свої особливості та області застосування [46].

Матриця невідповідностей є базовим інструментом для оцінки ефективності класифікаційної моделі. Вона показує кількість правильних і хибних передбачень, розділених за класами (рисунок 3.13).

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Рисунок 3.13 – Матриця невідповідностей

Матриця невідповідностей складається з чотирьох основних компонентів:

- кількість правильно передбачених позитивних зразків (істинно позитивні, TP);
- кількість правильно передбачених негативних зразків (істинно негативні, TN);

– кількість хибнопозитивних передбачень, коли модель передбачила позитивний клас, але фактично зразок був негативним (хибнопозитивні, FP);

– кількість хибнонегативних передбачень, коли модель передбачила негативний клас, але фактично зразок був позитивним (хибнонегативні, FN).

Матриця невідповідностей дозволяє легко обчислити інші метрики ефективності, такі як точність, чутливість, специфічність і F1-міра.

Точність є однією з найбільш базових метрик оцінки ефективності класифікаційної моделі. Вона визначається як відсоток правильних передбачень від загальної кількості передбачень.

$$\text{Точність} = \frac{TP+TN}{TP+TN+FP+FN}. \quad (3.19)$$

Хоча точність є простою та зрозумілою метрикою, вона може бути недостатньо інформативною для задач з незбалансованими класами, де кількість зразків одного класу значно перевищує кількість зразків іншого.

Чутливість, також відома як повнота, вимірює здатність моделі правильно ідентифікувати позитивні зразки. Вона визначається як відсоток правильних позитивних передбачень від загальної кількості фактичних позитивних зразків.

$$\text{Чутливість} = \frac{TP}{TP+FN}. \quad (3.20)$$

Чутливість є важливою метрикою для задач, де важливо мінімізувати пропущені позитивні випадки, наприклад, при виявленні захворювань.

Специфічність вимірює здатність моделі правильно ідентифікувати негативні зразки. Вона визначається як відсоток правильних негативних передбачень від загальної кількості фактичних негативних зразків.

$$\text{Специфічність} = \frac{TN}{TN+FP}. \quad (3.21)$$

Специфічність є важливою метрикою для задач, де важливо мінімізувати кількість хибних тривог, наприклад, при діагностиці рідкісних захворювань.

F1-міра є гармонічним середнім між чутливістю та точністю. Вона використовується для оцінки балансу між цими двома метриками, особливо в умовах незбалансованих класів.

$$F1\text{-міра} = 2 \cdot \frac{\text{Чутливість} \cdot \text{Точність}}{\text{Чутливість} + \text{Точність}}. \quad (3.22)$$

F1-міра забезпечує більш збалансовану оцінку продуктивності моделі, враховуючи як пропущені позитивні випадки, так і хибні тривоги.

ROC-крива є графічним способом оцінки продуктивності класифікаційної моделі, допомагає візуально оцінити здатність моделі розрізняти між позитивними і негативними зразками (рисунок 3.14).

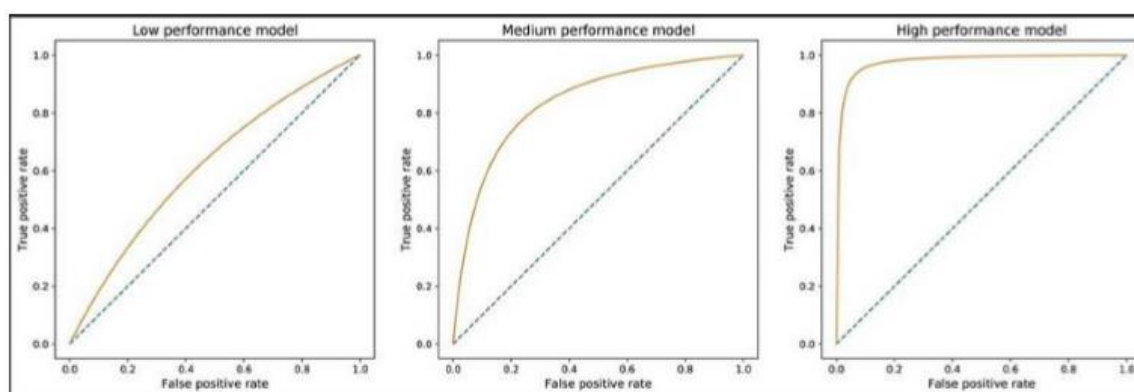


Рисунок 3.14 – ROC-крива

Ідеальна модель має ROC-криву, яка проходить через верхній лівий кут графіка, що вказує на високу чутливість і специфічність (0 хибнопозитивних передбачень). Модель, яка робить випадкові

передбачення, буде мати ROC-криву, що лежить на діагоналі від нижнього лівого кута до верхнього правого кута.

AUC (Area Under the Curve) є числовим показником, який вимірює загальну продуктивність класифікаційної моделі. AUC обчислюється як площа під ROC-кривою і варіюється від 0 до 1:

– $AUC = 1$: ідеальна модель, яка має 100% чутливість і 100% специфічність;

– $AUC = 0.5$: модель, яка робить випадкові передбачення і не має жодної дискримінаційної здатності;

– $AUC < 0.5$: модель, яка працює гірше за випадкові передбачення.

AUC-ROC є стійкою метрикою, яка не залежить від порогових значень, що робить її корисною для порівняння моделей. Вона дозволяє оцінити здатність моделі розрізняти між позитивними і негативними зразками по всьому спектру можливих порогів.

В аналізі МРТ-зображень ROC-крива та AUC використовуються для оцінки ефективності моделей, які класифікують зображення на категорії, наприклад, здорові та патологічні. Високий AUC вказує на те, що модель добре розрізняє між зразками з різними патологіями, що є критично важливим для надання точної діагностики та планування лікування.

4 ПРАКТИЧНА РЕАЛІЗАЦІЯ

У сучасному світі, де цифрові технології постійно розвиваються, застосування методів штучного інтелекту в медичній діагностиці набуває все більшої значущості. Визначення нейродегенеративних захворювань, таких як хвороба Альцгеймера, є критично важливим, оскільки ці захворювання мають високий рівень розповсюдженості і суттєво впливають на якість життя пацієнтів та їх сімей.

Метою цієї роботи є дослідження та оцінка потенціалу застосування методів штучного інтелекту для аналізу МРТ-зображень у діагностиці нейродегенеративних захворювань головного мозку. У практичній частині були використані та порівняні кілька моделей машинного навчання. Ці моделі були обрані на основі їх здатності ефективно обробляти зображення та знаходити складні залежності в даних.

Для дослідження був обраний відкритий набір даних Alzheimer's Dataset (4 class of Images) [47]. Цей набір містить 6400 МРТ-зображень головного мозку людей, розділених на чотири класи (рисунок 4.1):

- легке зниження когнітивних функцій (MildDemented);
- помірне зниження когнітивних функцій (ModerateDemented);
- без зниження когнітивних функцій (NonDemented);
- дуже легке зниження когнітивних функцій (VeryMildDemented).




Рисунок 4.1 – Класи МРТ-зображень

Важливою перевагою цього датасету є те, що з МРТ-знімків видалені ті фрагменти, які не впливають на визначення хвороби Альцгеймера, залишаючи тільки ділянки паренхіми мозку, які піддаються ураженню при цьому захворюванні.

Для розробки та тестування моделей використовувалося середовище Python, відоме своєю гнучкістю та широким спектром наукових і дослідницьких бібліотек. Зокрема, були використані бібліотеки TensorFlow і Keras для розробки нейронних мереж, а також NumPy і Pandas для обробки та аналізу даних.

TensorFlow і Keras надають зручні засоби для побудови, тренування та оцінювання моделей, що значно спрощує процес моделювання. Бібліотеки NumPy та Pandas забезпечують ефективні обчислення з масивами та матрицями, а також зручні функції для маніпуляцій з даними, такі як зчитування, фільтрація та трансформація датасетів.

4.1 Попередня обробка даних

Для успішного виконання завдання прогнозування стадій хвороби Альцгеймера на основі МРТ-знімків було проведено ретельну попередню обробку даних. Цей етап включав кілька важливих кроків, які забезпечили належну підготовку даних для подальшого навчання моделей.

Спочатку мітки класів, які визначають стадії хвороби (Non Demented, Very Mild Demented, Mild Demented, Moderate Demented), були перетворені з текстових значень на числові. Це було зроблено за допомогою функції `map` з бібліотеки `pandas`, яка дозволяє замінити текстові значення на відповідні числові коди. Після цього було виконано однократне кодування (`one-hot encoding`) міток класів за допомогою функції `get_dummies` з тієї ж бібліотеки. Цей крок забезпечив представлення міток у форматі, який підходить для тренування нейронних мереж.

Далі всі 6400 МРТ-знімків були розділені на тренувальний і тестовий набори даних у співвідношенні 80% до 20%. Для цього використовувалася функція `train_test_split` з бібліотеки `sklearn`. Такий поділ забезпечив можливість належного тренування моделей на основному обсязі даних та оцінки їхньої ефективності на незалежному тестовому наборі.

Для підвищення ефективності тренування моделей та збільшення різноманітності тренувальних даних була виконана аугментація зображень. Цей процес включав випадкове обертання зображень на 30° , масштабування, зміщення по висоті та ширині, а також горизонтальне та вертикальне відбивання зображень. Аугментація зображень була здійснена за допомогою класу `ImageDataGenerator` з бібліотеки `keras`. Це дозволило створити додаткові варіанти зображень з існуючих даних, що допомогло моделі краще узагальнювати знання та покращило її стійкість до різних варіацій у зображеннях.

4.2 Експлоративний аналіз

Експлоративний аналіз даних (EDA) є важливим кроком для розуміння структури і особливостей датасету перед побудовою моделей машинного навчання. Для цього завдання було обрано набір даних під назвою, який містить 6400 МРТ-знімків головного мозку, розділених на чотири класи: `Non Demented`, `Very Mild Demented`, `Mild Demented` і `Moderate Demented`.

Для кращого розуміння розподілу класів у датасеті, було побудовано гістограму, яка відображає кількість зображень у кожному класі. На рисунку 4.2 можна побачити, що класи `Mild Demented` та `Moderate Demented` є значно менш представленими порівняно з класами `Non Demented` і `Very Mild Demented`.




Рисунок 4.2 – Розподіл класів: Mild Demented (0), Moderate Demented (1), Non-Demented (2), Very Mild Demented (3)

Було проведено обчислення середнього зображення та зображення стандартного відхилення для кожного класу. МРТ-знімки містять різні зрізи мозку, але навіть за цих умов можна помітити відмінності між класами.

Для обчислення середнього зображення для кожного класу було взято середнє значення кожного пікселя для всіх зображень цього класу. Це дозволяє отримати узагальнене уявлення про типове зображення для кожного класу (рисунок 4.3).




Рисунок 4.3 – Середнє зображення для кожного класу

Так само для виявлення областей з найбільшою варіабельністю в кожному класі було обчислено дисперсію або стандартне відхилення кожного пікселя (рисунок 4.4). Світліші області на таких зображеннях вказують на вищу варіабельність.




Рисунок 4.4 – Стандартне відхилення

4.3 Розробка та навчання моделей

Для прогнозування ймовірності стадії хвороби Альцгеймера на основі МРТ-знімків було використано три архітектури згорткових нейронних мереж (CNN), попередньо навчених на датасеті ImageNet, а саме ResNet50, AlexNet та VGG16.

Підхід, який використовувався для вирішення цієї задачі, полягає в трансферному навчанні (transfer learning). Це метод, при якому тільки декілька вихідних шарів попередньо навчених мереж налаштовуються на нових даних. Решта шарів залишаються незмінними, що дозволяє зберегти вже наявні знання моделі та адаптувати її до нової задачі з мінімальними витратами часу на навчання.

Для створення моделі класифікації була розроблена загальна архітектура, яка включає базову частину у вигляді попередньо навчених мереж (ResNet50, AlexNet або VGG16) та додаткові шари для кінцевої класифікації. Загальна структура моделі (рисунок 4.5) виглядає наступним чином:

– базова модель: на першому етапі до архітектури додавалась одна з попередньо навчених моделей – ResNet50, AlexNet або VGG16. Ці моделі використовувались без верхніх (класифікаційних) шарів, а їхні попередньо навчені ваги залишались замороженими, що дозволяло зберегти високорівневі ознаки, витягнуті зображеннями;

– Flatten: вихідний об'ємний тензор базової моделі перетворювався в одномірний вектор за допомогою шару Flatten;

– додаткові щільні шари (Dense): перший щільний шар містив 512 нейронів з активаційною функцією ReLU та ініціалізацією ваг `he_uniform` для стабільного навчання, другий щільний шар містив 128 нейронів з аналогічними параметрами, третій щільний шар містив 32 нейрони з аналогічними параметрами;

– вихідний шар містив стільки нейронів, скільки є класів у задачі (4 у цьому випадку), з активаційною функцією Softmax для перетворення виходів у ймовірності класів.

```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
resnet50 (Functional)       (None, 2048)                23587712
-----
flatten (Flatten)           (None, 2048)                 0
-----
dense (Dense)                (None, 512)                 1049088
-----
dense_1 (Dense)              (None, 128)                 65664
-----
dense_2 (Dense)              (None, 32)                  4128
-----
dense_3 (Dense)              (None, 4)                   132
-----
Total params: 24,706,724
Trainable params: 1,119,012
Non-trainable params: 23,587,712
-----

```

Рисунок 4.5 – Структура моделі

Навчання моделей здійснювалося з використанням колбеків для контролю процесу навчання і оптимізації параметрів. Навчання було налаштоване на 100 епох, з використанням колбеків, що допомагають покращити ефективність і стабільність навчання:

– ModelCheckpoint: зберігає ваги моделі, якщо показник `val_accuracy` покращується. Це дозволяє зберігати найкращу модель з найвищою точністю на валідаційному наборі;

– EarlyStopping: зупиняє навчання, якщо показник `val_accuracy` не покращується протягом 5 епох, що запобігає перенавчанню моделі. Навчання моделі ResNet50 завершилося після 24 епох, AlexNet – після 9 епох, VGG16 – після 32 епох;

– ReduceLRonPlateau: зменшує швидкість навчання на фактор 0.2, якщо `val_accuracy` не покращується протягом 3 епох. Це допомагає моделі знайти оптимальне значення швидкості навчання для кращої збіжності.

Моделі компілювалися з оптимізатором Adam, функцією втрат `CategoricalCrossentropy` і визначеними метриками (рисунк 4.7 – 4.8).




Рисунок 4.6 – Метрики моделі ResNet50




Рисунок 4.7 – Метрики моделі AlexNet

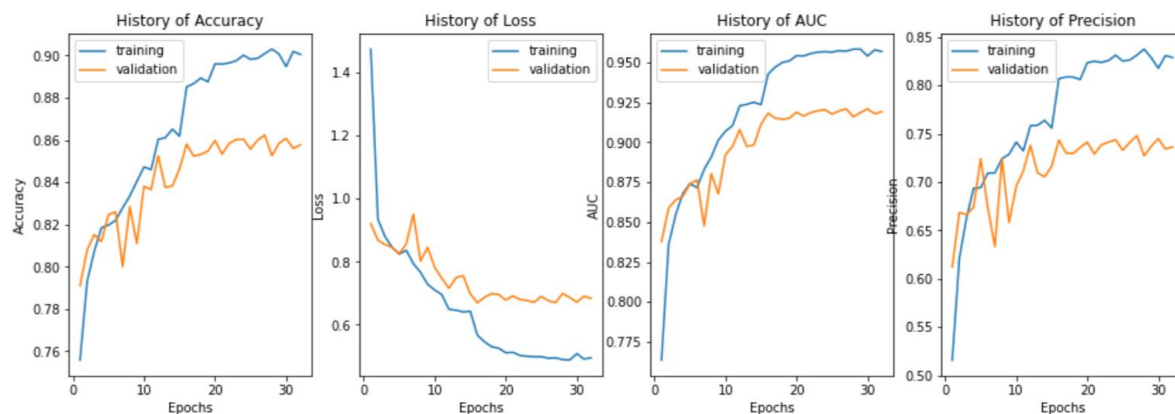


Рисунок 4.8 – Метрики моделі VGG16

Кожна з використаних архітектур (ResNet50, AlexNet, VGG16) повертає ймовірність належності зображення до кожного з класів і присвоює зображенню клас з найвищою ймовірністю. Це дозволяє моделі автоматично класифікувати МРТ-знімки на один з чотирьох класів: Non Demented, Very Mild Demented, Mild Demented та Moderate Demented.

4.4 Аналіз результатів

Для оцінки роботи моделей, розроблених у попередньому підрозділі, було використано декілька методів візуалізації та аналізу результатів. Один із методів включає візуалізацію зображень з їхніми передбаченими та фактичними мітками.

На рисунку 4.9 показані зображення з тестового набору даних з їхніми передбаченими та фактичними мітками. Ця візуалізація дозволяє побачити, як модель справляється з класифікацією різних стадій когнітивних порушень.

Зображення чітко показують випадки, коли моделі правильно ідентифікують стадії хвороби, а також випадки, коли вони роблять помилки. Наприклад, можна побачити, що моделі часто плутають стадії Very Mild

Demented з Non Demented, що вказує на те, що між цими стадіями є деякі схожі ознаки, які моделі не можуть чітко розрізнити.

Ця візуалізація не тільки дозволяє побачити, де саме моделі помиляються, але й дає змогу краще зрозуміти природу цих помилок. Наприклад, якщо модель часто помиляється між певними класами, це може вказувати на необхідність додаткових даних для навчання або вдосконалення існуючих даних для цих конкретних класів.




Рисунок 4.9 – МРТ-зображення з передбаченими та фактичними мітками

Крім того, такі візуалізації можуть допомогти виявити структурні подібності між зображеннями різних класів, що може бути корисним для подальшого покращення моделі. Наприклад, можна виявити, що деякі класи мають спільні риси, які вводять модель в оману, що може бути корисно для наступних ітерацій навчання та налаштування моделей.

Матриця невідповідностей дозволяє оцінити продуктивність класифікаційної моделі, показуючи кількість правильних та неправильних передбачень для кожного класу. На рисунках 4.10–4.12 наведені матриці невідповідностей для моделей.

З матриці невідповідностей видно, що модель ResNet50 найкраще класифікує зображення класу NonDemented, оскільки 646 зображень були правильно класифіковані, і жодне не було неправильно передбачене як інший клас. Це відповідає високій точності класифікації цього класу.

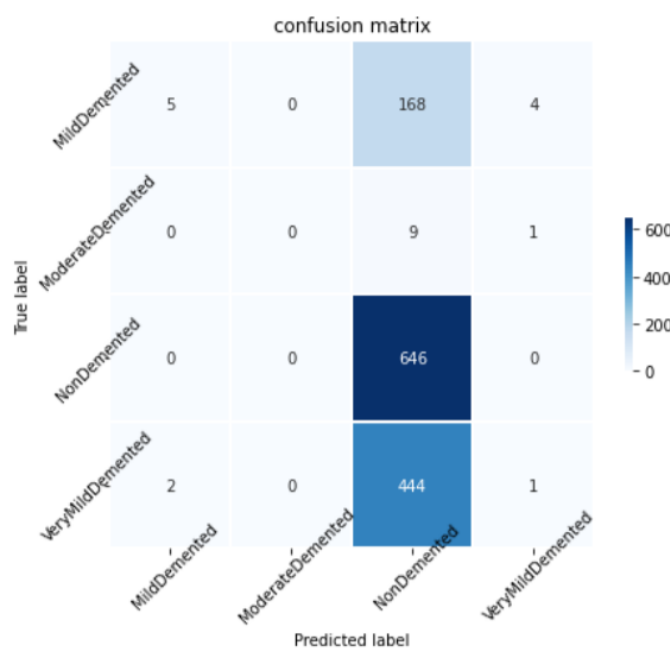


Рисунок 4.10 – Матриця невідповідностей для моделі ResNet50

Однак модель має значні проблеми з класифікацією зображень класів MildDemented та VeryMildDemented. Зокрема, більшість зображень класу VeryMildDemented були неправильно класифіковані як NonDemented (444 випадки), що свідчить про значну плутанину між цими двома класами. Це може бути спричинено тим, що ознаки дуже слабого зниження когнітивних функцій можуть бути схожими на нормальний стан, що робить їх складними для точного розрізнення.

Ситуація з MildDemented ще гірша: більшість цих зображень були класифіковані як NonDemented (168 випадків), що також вказує на значну плутанину. Крім того, модель зовсім не змогла правильно класифікувати зображення з класу ModerateDemented, що також є важливим аспектом для покращення.

Результати тестування моделі ResNet50 показують такі значення метрик: F1-score (testing) становить 34.99%, а accuracy (testing) – 50.94%. Ці показники підтверджують висновки, зроблені на основі матриці плутанини. Низьке значення F1-score свідчить про те, що модель має проблеми з балансом між точністю (precision) та повнотою (recall).




Рисунок 4.11 – Матриця невідповідностей для моделі AlexNet

З матриці невідповідностей, що модель AlexNet найкраще класифікує зображення класу NonDemented, оскільки всі 646 зображень цього класу були правильно класифіковані. Це свідчить про високу здатність моделі розпізнавати нормальний стан. Однак модель має значні проблеми з класифікацією інших класів.

Усі 177 зображень класу MildDemented були неправильно класифіковані як NonDemented. Аналогічна ситуація спостерігається для класу ModerateDemented, де всі 10 зображень також були класифіковані як NonDemented. Щодо класу VeryMildDemented, то всі 447 зображень були класифіковані як NonDemented. Це вказує на значну плутанину між класами, де ознаки слабого, помірного та дуже слабого порушення когнітивних функцій неправильно розпізнаються як нормальний стан.

Результати тестування моделі показують такі значення метрик: F1 Score (testing) становить 33.86%, а accuracy (testing) – 50.47%.

З матриці невідповідностей (рисунок 4.12) видно, що модель VGG16 найкраще класифікує зображення класу NonDemented. Із 646 зображень цього класу 633 були правильно класифіковані, що свідчить про високу точність класифікації цього класу.




Рисунок 4.12 – Матриця невідповідностей для моделі VGG16

Однак модель має деякі проблеми з класифікацією класів MildDemented та VeryMildDemented. Зокрема, 154 зображення класу MildDemented та 384 зображення класу VeryMildDemented були неправильно класифіковані як NonDemented. Це свідчить про те, що модель плутає ознаки слабого зниження когнітивних функцій та дуже слабого з нормальним станом, що знижує загальну продуктивність класифікації.

Результати тестування моделі показують такі значення метрик: F1 Score (testing) становить 42.65%, а accuracy (testing) – 53.91%.

ВИСНОВКИ

В ході роботи було розглянуто основні характеристики нейродегенеративних захворювань, їх види, причини та особливості перебігу. Це дозволило краще зрозуміти, які ознаки та патерни на МРТ-зображеннях є ключовими для діагностики. Також було вивчено різні методи передобробки МРТ-зображень, включаючи фільтрацію шумів, корекцію контрасту, нормалізацію та вирівнювання гомогенності, що дозволяє покращити якість зображень та підготувати їх для подальшого аналізу.

Досліджено різні алгоритми машинного навчання та глибинного навчання для аналізу МРТ-зображень, а також згорткові нейронні мережі (CNN), автокодувальники та рекурентні нейронні мережі (RNN). Це дозволило провести порівняльний аналіз ефективності різних підходів до обробки та аналізу медичних зображень. Огляд сучасних досліджень, показав, що методи штучного інтелекту, зокрема згорткові нейронні мережі, демонструють високу ефективність у цій галузі.

Було розроблено та навчено три моделі згорткових нейронних мереж (ResNet50, AlexNet, VGG16), використовуючи метод трансферного навчання. Моделі добре справилися з класифікацією лише класу NonDemented (без зниження когнітивних функцій), тоді як інші класи класифікувалися набагато гірше. Це свідчить про дисбаланс у даних або про недостатню здатність моделі розрізняти ознаки різних класів. Модель VGG16 показала найвищу точність (53.91%) та F1-score (42.65%) серед досліджуваних моделей, однак результати потребують подальшого покращення.

Для подальшого вдосконалення моделей рекомендується зібрати більший обсяг даних, особливо для класів, які наразі недостатньо представлені. Крім того, доцільно застосувати більш складні методи

обробки даних та використати ансамблеві методи для підвищення точності класифікації.

Таким чином, результати цього дослідження демонструють, що методи штучного інтелекту мають великий потенціал для використання в аналізі МРТ-зображень та діагностиці нейродегенеративних захворювань головного мозку, проте потребують подальшого вдосконалення для досягнення клінічно значущих результатів.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

- 1) Neurodegenerative Diseases. *MedlinePlus – Health Information from the National Library of Medicine*. URL: <https://medlineplus.gov/degenerativenervediseases.html> (date of access: 06.02.2024).
- 2) Checkoway H., Lundin J.I., Kelada S.N. Neurodegenerative diseases. *IARC Sci. Publ.* 2011. No.163. P. 407–419.
- 3) Hallmarks of neurodegenerative diseases / D. M. Wilson et al. *Cell*. 2023. Vol. 186, no. 4. P. 693–714. URL: <https://doi.org/10.1016/j.cell.2022.12.032> (date of access: 06.02.2024).
- 4) Neurodegenerative disease. *Physiopedia*. URL: https://www.physio-pedia.com/Neurodegenerative_Disease (date of access: 09.02.2024).
- 5) JPND neurodegenerative disease research. *JPND Neurodegenerative Disease Research*. URL: <https://neurodegenerationresearch.eu/what/> (date of access: 10.02.2024).
- 6) Risacher S. L., Saykin A. J. Neuroimaging advances in neurologic and neurodegenerative diseases. *Neurotherapeutics*. 2021. Vol. 18, no. 2. P. 659–660. URL: <https://doi.org/10.1007/s13311-021-01105-7> (date of access: 10.02.2024).
- 7) Brain MRI slices classification using least squares support vector machine / H. Selvaraj et al. *International journal of intelligent computing in medical sciences & image processing*. 2007. Vol. 1, no. 1. P. 21–33. URL: <https://doi.org/10.1080/1931308x.2007.10644134> (date of access: 17.02.2024).
- 8) A hybrid method for MRI brain image classification / Y. Zhang et al. *Expert systems with applications*. 2011. Vol. 38, no. 8. P. 10049–10053. URL: <https://doi.org/10.1016/j.eswa.2011.02.012> (date of access: 17.02.2024).
- 9) Nazir M., Wahid F., Ali Khan S. A simple and intelligent approach for brain MRI classification. *Journal of intelligent & fuzzy systems*. 2015. Vol. 28, no. 3. P. 1127–1135. URL: <https://doi.org/10.3233/ifs-141396> (date of access: 21.02.2024).

10) Diagnosis of Alzheimer's disease via multi-modality 3D convolutional neural network / Y. Huang et al. *Frontiers in neuroscience*. 2019. Vol. 13. URL: <https://doi.org/10.3389/fnins.2019.00509> (date of access: 22.02.2024).

11) Islam J., Zhang Y. Brain MRI analysis for Alzheimer's disease diagnosis using an ensemble system of deep convolutional neural networks. *Brain informatics*. 2018. Vol. 5, no. 2. URL: <https://doi.org/10.1186/s40708-018-0080-3> (date of access: 27.02.2024).

12) Automated classification of Alzheimer's disease and mild cognitive impairment using a single MRI and deep neural networks / S. Basaia et al. *NeuroImage: clinical*. 2019. Vol. 21. P. 101645. URL: <https://doi.org/10.1016/j.nicl.2018.101645> (date of access: 27.02.2024).

13) Machine learning based hierarchical classification of frontotemporal dementia and Alzheimer's disease / J. P. Kim et al. *NeuroImage: clinical*. 2019. Vol. 23. P. 101811. URL: <https://doi.org/10.1016/j.nicl.2019.101811> (date of access: 03.03.2024).

14) Detection of mild cognitive impairment in a community-dwelling population using quantitative, multiparametric MRI-based classification / M. J. R. J. Bouts et al. *Human brain mapping*. 2019. Vol. 40, no. 9. P. 2711–2722. URL: <https://doi.org/10.1002/hbm.24554> (date of access: 07.03.2024).

15) Early detection of Alzheimer's disease using magnetic resonance imaging: a novel approach combining convolutional neural networks and ensemble learning / D. Pan et al. *Frontiers in neuroscience*. 2020. Vol. 14. URL: <https://doi.org/10.3389/fnins.2020.00259> (date of access: 07.03.2024).

16) Suhas S., Venugopal C. R. MRI image preprocessing and noise removal technique using linear and nonlinear filters. *2017 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECCOT)*, Mysuru, 15–16 December 2017. 2017. URL: <https://doi.org/10.1109/iceeccot.2017.8284595> (date of access: 18.03.2024).

17) Ali H. M. MRI medical image denoising by fundamental filters. *High-Resolution neuroimaging – basic physical principles and clinical applications*. 2018. URL: <https://doi.org/10.5772/intechopen.72427> (date of access: 18.03.2024).

18) Non-Local operational anisotropic diffusion filter / F. M. Cappabianco et al. *2019 IEEE International Conference on Image Processing (ICIP)*, Taipei, Taiwan, 22–25 September 2019. 2019. URL: <https://doi.org/10.1109/icip.2019.8802958> (date of access: 20.03.2024).

19) Zaroubi S., Goelman G. Complex denoising of MR data via wavelet analysis: Application for functional MRI. *Magnetic resonance imaging*. 2000. Vol. 18, no. 1. P. 59–68. URL: [https://doi.org/10.1016/s0730-725x\(99\)00100-9](https://doi.org/10.1016/s0730-725x(99)00100-9) (date of access: 20.03.2024).

20) Krissian K., Aja-Fernandez S. Noise-Driven anisotropic diffusion filtering of MRI. *IEEE Transactions on Image Processing*. 2009. Vol. 18, no. 10. P. 2265–2274. URL: <https://doi.org/10.1109/tip.2009.2025553> (date of access: 20.03.2024).

21) Akdemir Akar S. Determination of optimal parameters for bilateral filter in brain MR image denoising. *Applied Soft Computing*. 2016. Vol. 43. P. 87–96. URL: <https://doi.org/10.1016/j.asoc.2016.02.043> (date of access: 21.03.2024).

22) Comparative study on histogram equalization techniques for medical image enhancement / S. Patel et al. *Advances in Intelligent Systems and Computing*. Singapore, 2019. P. 657–669. URL: https://doi.org/10.1007/978-981-15-0035-0_54 (date of access: 18.05.2024).

23) Perumal S., Velmurugan T. Preprocessing by contrast enhancement techniques for medical images. *International Journal of Pure and Applied Mathematics*. 2018. Vol. 118. No. 18. P.3681–3688.

24) Kalyani J., Chakraborty M. Contrast enhancement of MRI images using histogram equalization techniques. *2020 International Conference on Computer, Electrical & Communication Engineering*, Kolkata, India, 17–18

January 2020. 2020. URL: <https://doi.org/10.1109/iccece48148.2020.9223088> (date of access: 02.04.2024).

25) A post-processing algorithm for boosting contrast of MRI images / B. Priestly Shan et al. *Computers, Materials & Continua*. 2022. Vol. 72, no. 2. P. 2749–2763. URL: <https://doi.org/10.32604/cmc.2022.023057> (date of access: 04.04.2024).

26) Schmid S. Image intensity normalization in medical imaging. *Medium*. URL: <https://medium.com/@susanne.schmid/image-normalization-in-medical-imaging-f586c8526bd1> (date of access: 08.04.2024).

27) Hussain S., Anwar S. M., Majid M. Segmentation of glioma tumors in brain using deep convolutional neural network. *Neurocomputing*. 2018. Vol. 282. P. 248–261. URL: <https://doi.org/10.1016/j.neucom.2017.12.032> (date of access: 08.04.2024).

28) Salem W.S., Seddik A.F., Ali H.F. A review on brain MRI image segmentation. *The Second International Conference on New Paradigms in Electronics and Information Technologies PEIT'013*. Luxor, Egypt. 30 November – 03 December 2013. 2013.

29) Kalaiselvi T., Sriramakrishnan P., Somasundaram K. Survey of using GPU CUDA programming model in medical image analysis. *Informatics in Medicine Unlocked*. 2017. Vol. 9. P. 133–144. URL: <https://doi.org/10.1016/j.imu.2017.08.001> (date of access: 10.04.2024).

30) Dhankhar S., Tyagi S., Prasad T. Brain MRI segmentation using K-means algorithm. *National Conference on Advances in Knowledge Management, NCAKM 2010*. Lingaya's University, Faridabad, Haryana, India. 2010.

31) Al-Awadi J. Y. R., Aljobouri H. K., Hasan A. M. MRI brain scans classification using extreme learning machine on LBP and GLCM. *International Journal of Online and Biomedical Engineering (iJOE)*. 2023. Vol. 19, no. 02. P. 134–149. URL: <https://doi.org/10.3991/ijoe.v19i02.33987> (date of access: 19.04.2024).

32) Decision tree algorithm. A complete guide. *Analytics Vidhya*. URL: <https://www.analyticsvidhya.com/blog/2021/08/decision-tree-algorithm/> (date of access: 23.04.2024).

33) The importance of decision trees in machine learning. *Turing*. URL: <https://www.turing.com/kb/importance-of-decision-trees-in-machine-learning> (date of access: 23.04.2024).

34) Guide on support vector machine algorithm. *Analytics Vidhya*. URL: <https://www.analyticsvidhya.com/blog/2021/10/support-vector-machinessvm-a-complete-guide-for-beginners/> (date of access: 24.04.2024).

35) An overview of bayesian networks in artificial intelligence. *AI-Powered Engineering Services, LLM Training, Teams | Turing*. URL: <https://www.turing.com/kb/an-overview-of-bayesian-networks-in-ai> (date of access: 26.04.2024).

36) Understand random forest algorithms (updated 2024). *Analytics Vidhya*. URL: <https://www.analyticsvidhya.com/blog/2021/06/understanding-random-forest/> (date of access: 27.04.2024).

37) Linear regression vs logistic regression. *www.javatpoint.com*. URL: <https://www.javatpoint.com/linear-regression-vs-logistic-regression-in-machine-learning> (date of access: 28.04.2024).

38) Sumanta. XGBoost by heart. *Medium*. URL: <https://medium.com/almabetter/xgboost-by-heart-b494a471845e> (date of access: 02.05.2024).

39) K-Nearest neighbor (KNN) algorithm. *GeeksforGeeks*. URL: <https://www.geeksforgeeks.org/k-nearest-neighbours/> (date of access: 02.05.2024).

40) Introduction to convolution neural network. *GeeksforGeeks*. URL: <https://www.geeksforgeeks.org/introduction-convolution-neural-network/> (date of access: 05.05.2024).

41) Autoencoders – machine learning. *GeeksforGeeks*. URL: <https://www.geeksforgeeks.org/auto-encoders/> (date of access: 09.05.2024).

42) Introduction to recurrent neural network. *GeeksforGeeks*. URL: <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/> (date of access: 09.05.2024).

43) Tutorial on RNN | LSTM: with implementation. *Analytics Vidhya*. URL: <https://www.analyticsvidhya.com/blog/2022/01/tutorial-on-rnn-lstm-gru-with-implementation/> (date of access: 09.05.2024).

44) A novel CNN architecture for accurate early detection and classification of Alzheimer's disease using MRI data / A. M. El-Assy et al. *Scientific reports*. 2024. Vol. 14, no. 1. URL: <https://doi.org/10.1038/s41598-024-53733-6> (date of access: 10.05.2024).

45) Classification of parkinson's disease in patch-based MRI of substantia nigra / S. S. Hussain et al. *Diagnostics*. 2023. Vol. 13, no. 17. P. 2827. URL: <https://doi.org/10.3390/diagnostics13172827> (date of access: 10.05.2024).

46) Metrics to evaluate your classification model to take the right decisions. *Analytics Vidhya*. URL: <https://www.analyticsvidhya.com/blog/2021/07/metrics-to-evaluate-your-classification-model-to-take-the-right-decisions/> (date of access: 10.05.2024).

47) Alzheimer's dataset (4 class of images). *Kaggle: Your Machine Learning and Data Science Community*. URL: <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images> (date of access: 10.05.2024).