

Міністерство освіти і науки України
Тернопільський національний технічний університет імені Івана Пулюя

Факультет комп'ютерно-інформаційних систем і програмної інженерії
(повна назва факультету)

Кафедра комп'ютерних наук
(повна назва кафедри)

КВАЛІФІКАЦІЙНА РОБОТА

на здобуття освітнього ступеня

Магістр

(назва освітнього ступеня)

на тему: Інформаційна система для діагностики хвороби Альцгеймера з
використанням нейронних мереж

Виконав: студент VI курсу, групи СНм-61

спеціальності 122 Комп'ютерні науки

(шифр і назва спеціальності)

(підпис)

Роган Я.І.

(прізвище та ініціали)

Керівник

(підпис)

Фриз М.Є.

(прізвище та ініціали)

Нормоконтроль

(підпис)

Никитюк В.В.

(прізвище та ініціали)

Завідувач кафедри

(підпис)

Боднарчук І.О.

(прізвище та ініціали)

Рецензент

(підпис)

Осухівська Г.М.

(прізвище та ініціали)

Тернопіль
2024

Міністерство освіти і науки України
Тернопільський національний технічний університет імені Івана Пулюя

Факультет комп'ютерно-інформаційних систем і програмної інженерії
(повна назва факультету)
Кафедра комп'ютерних наук
(повна назва кафедри)

ЗАТВЕРДЖУЮ
Завідувач кафедри
Боднарчук І.О.
(підпис) (прізвище та ініціали)
« 25 » грудня 2024 р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

на здобуття освітнього ступеня Магістр
(назва освітнього ступеня)
за спеціальністю 122 Комп'ютерні науки
(шифр і назва спеціальності)
Студенту Рогану Ярославу Ігоровичу
(прізвище, ім'я, по батькові)

1. Тема роботи Інформаційна система для діагностики хвороби Альцгеймера з використанням нейронних мереж

Керівник роботи Фриз Михайло Євгенович, к.т.н., доцент кафедри КН
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

Затверджені наказом ректора від « 29 » листопада 2024 року № 4/7-1138
2. Термін подання студентом завершеної роботи 17 грудня 2024р.
3. Вихідні дані до роботи Наукові публікації про діагностику хвороби Альцгеймера з використанням нейронних мереж

4. Зміст роботи (перелік питань, які потрібно розробити)
Вступ.
1 Аналітичний огляд літературних джерел за напрямом дослідження.
2 Опис інформаційної системи.
3 Розробка та тестування системи
4 Охорона праці та безпека в надзвичайних ситуаціях.
Висновки.
Додатки.
5. Перелік графічного матеріалу (з згасточним зазначенням обов'язкових креслень, слайдів)
1 Титульна сторінка. 2 Анотація. 3 Актуальність дослідження та наукова новизна. 4 Вступ.
5 Діагностика хвороби Альцгеймера. 6 Аналітичний огляд літератури. 7 Набір даних.
8 Архітектура інформаційної системи. 9 Метрики оцінки точності. 10 Результати тренування моделі. 11 GRAD-CAM. 12 Аналіз результатів з GRAD-CAM. 13. Висновки. 14 Завершальний слайд.

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Охорона праці	Сенчишин В.С., доцент		
Безпека в надзвичайних ситуаціях	Клепчик В.М., ст. викладач		

7. Дата видачі завдання 29 листопада 2024 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1.	Ознайомлення з завданням до кваліфікаційної роботи	29.11.2024	Виконано
2.	Підбір наукових джерел про діагностику хвороби Альцгеймера з використанням нейронних мереж	29.11.2024-04.12.2024	Виконано
3.	Опрацювання наукових публікацій та збір даних по темі роботи	29.11.2024-04.12.2024	Виконано
4.	Виконання дослідження згідно мети кваліфікаційної роботи	05.12.2024-09.12.2024	Виконано
5.	Оформлення розділу «Аналітичний огляд літературних джерел за напрямом дослідження»	05.12.2024-09.12.2024	Виконано
6.	Оформлення розділу «Опис інформаційної системи»	05.12.2024-09.12.2024	Виконано
7.	Оформлення розділу «Розробка та тестування системи»	05.12.2024-09.12.2024	Виконано
8.	Виконання завдання до підрозділу «Охорона праці»	02.12.2024-09.12.2024	Виконано
9.	Виконання завдання до підрозділу «Безпека в надзвичайних ситуаціях»	02.12.2024-09.12.2024	Виконано
10.	Оформлення кваліфікаційної роботи	10.12.2024-11.12.2024	Виконано
11.	Нормоконтроль	12.12.2024-13.12.2024	Виконано
12.	Перевірка на плагіат	16.12.2024	Виконано
13.	Попередній захист кваліфікаційної роботи	17.12.2024	Виконано
14.	Захист кваліфікаційної роботи	26.12.2024	

Студент

(підпис)

Роган Я.І.

(прізвище та ініціали)

Керівник роботи

(підпис)

Фриз М.Є.

(прізвище та ініціали)

АНОТАЦІЯ

Інформаційна система для діагностики хвороби Альцгеймера з використанням нейронних мереж // Кваліфікаційна робота освітнього рівня «Магістр» // Роган Ярослав Ігорович // Тернопільський національний технічний університет імені Івана Пулюя, факультет комп'ютерно-інформаційних систем і програмної інженерії, кафедра комп'ютерних наук, група СНм-61 // Тернопіль, 2024 // С. 71, рис. – 19, табл. – 1, додат. – 1, бібліогр. – 52.

Ключові слова: хвороба Альцгеймера, діагностика хвороби, інформаційна система, машинне навчання, нейронні мережі, МРТ головного мозку, навчання нейронної мережі, Grad-CAM.

Кваліфікаційна робота присвячена розробці інформаційної системи для діагностики хвороби Альцгеймера з використанням нейронних мереж.

В першому розділі кваліфікаційної роботи описано предметне середовище та проаналізовано літературні джерела.

В другому розділі кваліфікаційної роботи проаналізовано предметну область та описано підготовку даних для навчання нейронної мережі.

В третьому розділі кваліфікаційної роботи описано засоби розробки, проаналізовано результати роботи нейронної мережі Inception V3 та реалізовано алгоритм Grad-CAM.

В четвертому розділі кваліфікаційної роботи проаналізовано важливість дотримання норм охорони праці та заходів безпеки в надзвичайних ситуаціях та розглянуто аспекти безпеки, пов'язані з використанням комп'ютерного обладнання та програмного забезпечення.

Об'єкт дослідження: процес здійснення діагностики хвороби Альцгеймера.

Предмет дослідження: методи штучного інтелекту, зокрема нейронні мережі для діагностики хвороби Альцгеймера.

[Введіть текст тут]

ANNOTATION

Information system for diagnosing of Alzheimer's disease using neural networks // The educational level "Master" qualification work // Rohan Yaroslav // Ternopil Ivan Pulyuy National Technical University, Faculty of Computer Information Systems and Software Engineering, Department of Computer Science, SNm-61 group // Ternopil, 2024 // P. 71, fig. - 19, tables - 1, annexes - 1, ref. - 52.

Key words: Alzheimer's disease, disease diagnostics, information system, machine learning, neural networks, brain MRI, neural network training, Grad-CAM.

Thesis is devoted to the development of an information system for diagnosing Alzheimer's disease using neural networks.

The first chapter of the thesis describes the subject environment and analyzes the literature.

The second chapter of the qualification work analyzes the subject area and describes the preparation of data for training a neural network.

The third section of the qualification work describes the development tools, analyzes the results of the Inception V3 neural network and implements the Grad-CAM algorithm.

The fourth chapter of the qualification work analyzes the importance of compliance with labor protection standards and safety measures in emergency situations and considers the safety aspects associated with the use of computer hardware and software.

Object of research: an information system for diagnosing Alzheimer's disease.

Subject of research: methods of artificial intelligence, in particular neural networks for diagnosing Alzheimer's disease.

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

ЕЕГ – Електроенцефалографія.

КТ – Комп'ютерна томографія.

МРТ – Магнітно-резонансна томографія.

ПЕТ – Позитрон-емісійна томографія.

ТМС – Транскраніальна магнітна стимуляція

ХА – Хвороба Альцгеймера.

ІІ – Штучний інтелект.

CNN (англ. Convolutional Neural Network) – згорткова нейронна мережа.

GNN (англ. Graph Neural Network) – графова нейронна мережа.

ЗМІСТ

ВСТУП.....	10
1 АНАЛІТИЧНИЙ ОГЛЯД ЛІТЕРАТУРНИХ ДЖЕРЕЛ ЗА НАПРЯМОМ ДОСЛІДЖЕННЯ	12
1.1 Огляд хвороби Альцгеймера	12
1.2 Аналіз методів діагностики хвороби Альцгеймера з використанням машинного навчання	15
1.3 Висновки до першого розділу	23
2 ОПИС ІНФОРМАЦІЙНОЇ СИСТЕМИ.....	25
2.1 Дані та їх аугментація	25
2.2 Опис методів штучного інтелекту для обробки медичних зображень	27
2.3 Архітектура інформаційної системи	35
2.4 Висновки до другого розділу	40
3 РОЗРОБКА ТА ТЕСТУВАННЯ СИСТЕМИ	41
3.1 Тренування нейронної мережі.....	41
3.2 Аналіз отриманих результатів з використанням Grad-CAM	48
3.3 Висновки до третього розділу	51
4 ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ.....	53
4.1 Організація робочого місця для користувачів комп'ютерної мережі	53
4.2 Фактори ризику і можливі порушення здоров'я користувачів комп'ютерної мережі.....	57
4.3 Висновок до четвертого розділу	61
ВИСНОВКИ	62
ПЕРЕЛІК ДЖЕРЕЛ	64
ДОДАТКИ	

ВСТУП

Актуальність дослідження полягає у тому, що розробка інформаційної системи для діагностики хвороби Альцгеймера за допомогою нейронних мереж сприяє підвищенню точності діагностики, а також оптимізації процесів лікування та догляду за пацієнтами, що є критично важливим для боротьби з цією серйозною когнітивною хворобою.

Мета і задачі дослідження. Метою даної кваліфікаційної роботи освітнього рівня «Магістр» є підвищення ефективності процесу діагностики хвороби Альцгеймера шляхом створення та використання інформаційної системи на основі використання нейронних мереж. Для досягнення поставленої мети потрібно виконати ряд завдань, зокрема:

- Проаналізувати стан досліджень в області хвороби Альцгеймера.
- Дослідити існуючі на даний час методи діагностики захворювання.
- Проаналізувати методи штучного інтелекту, зокрема нейронні мережі.
- Розробити інформаційну систему на основі нейронних мереж.

Об'єктом дослідження є процес здійснення діагностики хвороби Альцгеймера.

Предметом дослідження є методи штучного інтелекту, зокрема нейронні мережі для діагностики хвороби Альцгеймера.

Наукова новизна одержаних результатів кваліфікаційної роботи полягає у тому, що отримано подальший розвиток методу діагностики хвороби Альцгеймера з використанням нейронних мереж.

Практичне значення одержаних результатів. Створено інформаційну систему для діагностики хвороби Альцгеймера за допомогою нейронних мереж.

Апробація результатів магістерської роботи. Основні результати проведених досліджень обговорювались на XII науково-технічній конференції «Інформаційні моделі, системи та технології» Тернопільського національного технічного університету імені Івана Пулюя (м. Тернопіль, 2024 р.).

Публікації. Основні результати кваліфікаційної роботи опубліковано у двох працях конференції (Див. додатки А).

Структура й обсяг кваліфікаційної роботи. Кваліфікаційна робота складається зі вступу, чотирьох розділів, висновків, списку літератури з 52 найменувань та 1 додатку. Загальний обсяг кваліфікаційної роботи складає 71 сторінку, з них 49 сторінок основного тексту, який містить 19 рисунків та 1 таблицю.

1 АНАЛІТИЧНИЙ ОГЛЯД ЛІТЕРАТУРНИХ ДЖЕРЕЛ ЗА НАПРЯМОМ ДОСЛІДЖЕННЯ

1.1 Огляд хвороби Альцгеймера

Хвороба Альцгеймера [1] – це патологічне захворювання, що вражає мозок і призводить до погіршення когнітивних функцій, таких як: пам'ять, увага, мовлення та мислення. Вона є найпоширенішою формою деменції [2], особливо серед людей похилого віку. Хвороба Альцгеймера розвивається через комбінацію генетичних, екологічних і біологічних факторів, зокрема накопичення білків у мозку, генетична схильність, вік та серцево-судинні фактори. Серед усіх факторів найважливішим є вік, адже частота захворювання значно зростає після 65 років, що робить людей цієї групи населення найбільш вразливими по відношенню до цієї хвороби.

На ранніх стадіях пацієнти можуть відчувати легкі порушення пам'яті, зокрема забуття недавніх подій. З прогресуванням хвороби з'являються проблеми з виконанням звичайних завдань, дезорієнтація в часі і просторі та зміни настрою. На пізніх же стадіях пацієнти повністю втрачають здатність до самостійного існування та потребують постійного догляду.

Хвороба Альцгеймера зазвичай вражає людей старшого віку, зокрема старших за 65 років. У світі понад 55 мільйонів людей живуть з деменцією, яка потім переходить в складнішу форму хвороби Альцгеймера. Кожні 20 років ця кількість стає вдвічі більшою через старіння населення. Дане захворювання є глобальною медичною та соціальною проблемою. Завдяки ранній діагностиці, сучасним методам лікування та профілактики можна значно покращити якість життя пацієнтів і їхніх близьких.

Діагностика ХА складається з декількох етапів, які поєднуються для оптимізації та покращення точності діагнозу. Комплексний підхід дозволяє оглянути пацієнта з використанням різних методів, зокрема клінічних, фізичних та лабораторних. Діагностика цього захворювання вимагає поєднання різних підходів для точної ідентифікації захворювання та його стадії.

Першим етапом є збір інформації про пацієнта, включно з історією хвороби та іншими необхідними даними, які можна буде використати для аналізу. Велика увага приділяється спостереженням родичів та близьких пацієнта, оскільки вони можуть помітити поведінкові або когнітивні зміни, які сам хворий може не усвідомлювати через активізацію хвороби.

Клінічні обстеження включають в себе оцінку когнітивних функцій за допомогою психологічних тестів, таких як: MMSE (Mini-Mental State Examination) [3] та MoCA (Montreal Cognitive Assessment) [4]. Ці методи допомагають оцінити пам'ять, увагу, мовлення та просторове мислення. Однак самі по собі такі тести не дають змоги остаточно поставити діагноз, оскільки когнітивні порушення можуть бути спричинені іншими захворюваннями.

Одним з типових завдань психологічного тесту MoCA є малювання годинника із стрілками, який показує час 2:30. Результати показують погіршення здатності пацієнта до обробки зображень в залежності від стадії хвороби. На рисунку 1.1 зображено результати проходження цього завдання трьома людьми: здоровим пацієнтом, пацієнтом з ранньою стадією ХА та пацієнтом з тяжкою формою ХА. Таким чином можна зрозуміти яким бачать світ люди з різною формою захворювання.



Рисунок 1.1 – Результати проходження завдання тесту MoCA

Важливим етапом є використання нейровізуалізаційних технологій, таких як магнітно-резонансна томографія (МРТ) [5], комп'ютерна томографія (КТ) [6] чи позитронна емісійна томографія (ПЕТ) [7]. Найточнішим нейровізуалізаційним методом для діагностики ХА є МРТ, що дозволяє виявити атрофію мозкових структур, зокрема гіпокампа, що характерно для хвороби Альцгеймера, а також підкреслити зміни у структурі мозку. Змінок МРТ дозволяє помітити відмінність між мозком здорового пацієнта та хворого навіть неозброєним оком, що можна побачити на рисунку 1.2, де наведено порівняння двох пацієнтів – здорового (зліва) та хворого (справа).




Рисунок 1.2 – Порівняння МРТ головного мозку

Проаналізувавши рисунок можна виділити візуальні особливості хвороби, зокрема атрофію всіх ділянок кори головного мозку, а також та збільшення пустот всередині мозку. Процес аналізу зображень МРТ головного мозку прямопропорційно залежить від розвитку інформаційних технологій відкриває нові можливості у діагностиці. Алгоритми штучного інтелекту можуть аналізувати медичні зображення або результати когнітивних тестів із високою точністю. Інформаційні технології також допомагають у розробці нових ліків і терапій, використовуючи моделювання захворювання на молекулярному рівні. Таким чином, вони значно підвищують шанси на раннє виявлення, ефективне лікування та покращення якості життя пацієнтів.

Дослідження хвороби Альцгеймера за допомогою нейронних мереж є важливим напрямом сучасної науки, що значно підвищує ефективність діагностики, прогнозування та розробки нових методів лікування. Завдяки здатності обробляти великі обсяги даних і знаходити приховані закономірності, нейронні мережі пропонують інноваційні підходи до аналізу біомедичних даних і вивчення складних процесів, пов'язаних із захворюванням.

Нейронні мережі дозволяють автоматизувати процеси аналізу медичних зображень. Завдяки цьому можна швидко і точно виявляти характерні ознаки хвороби, наприклад, атрофію мозкових структур. Алгоритми глибинного навчання аналізують зображення з точністю, що перевищує можливості традиційних методів, і здатні виявляти патології навіть на ранніх стадіях, коли симптоми ще не проявилися.

Нейронні мережі ефективно використовуються для прогнозування перебігу хвороби. Вони аналізують комбінацію клінічних даних, результатів тестів, генетичних факторів і зображень мозку, щоб передбачити, як швидко розвиватимуться когнітивні порушення. Це важливо для визначення оптимальної стратегії лікування та догляду за пацієнтом.

Хоча застосування нейронних мереж демонструє величезний потенціал, є і виклики. Це зокрема необхідність великих якісних наборів даних для тренування моделей, питання етичного використання даних пацієнтів і потреба в інтерпретованості алгоритмів. У майбутньому нейронні мережі можуть стати частиною рутинної медичної практики, інтегруючись у системи штучного інтелекту для підтримки прийняття рішень і персоналізації лікування.

Таким чином, нейронні мережі відкривають нові горизонти у розумінні, діагностиці та лікуванні хвороби Альцгеймера, що сприяє покращенню якості життя пацієнтів і їхніх родин.

1.2 Аналіз методів діагностики хвороби Альцгеймера з використанням машинного навчання

Літературний аналіз допомагає зібрати і систематизувати інформацію про сучасні методи використання нейронних мереж у діагностиці хвороби Альцгеймера. Аналіз дозволяє оцінити, які підходи є найбільш успішними, які мають обмеження, та в яких аспектах залишаються прогалини. Огляд наукових публікацій дозволяє порівняти результати різних досліджень, включаючи показники точності, чутливості, специфічності та стабільності моделей. Узагальнення таких даних дозволяє визначити найефективніші практики.

Аналіз літератури також сприяє виявленню нових напрямів досліджень і можливостей вдосконалення методів, а також допомагає зрозуміти, які з описаних методів можуть бути впроваджені в клінічну практику та які є перспективними для використання в реальних умовах. Більше того, аналіз літературних джерел не лише надає огляд існуючих методів і підходів, але й слугує основою для створення нових інноваційних рішень у діагностиці хвороби Альцгеймера, підвищуючи її точність і доступність.

Аналіз наукових робіт, які стосуються досліджень відповідних до теми кваліфікаційної роботи рівня «Магістр» було проведено за допомогою бази даних Scopus [8]. Scopus – це одна з найбільших у світі баз даних, яка охоплює рецензовані наукові публікації у різних галузях наук. Вона служить інструментом для дослідження, аналізу та оцінки наукових досягнень.

До переваг Scopus належить зручність пошуку, ефективні фільтри пошуку, інструменти аналізу, такі як: графіки, таблиці та візуалізації оцінок. Також великою перевагою є те, що дана база має широке охоплення: більше 77 мільйонів записів, що були опубліковані в понад 27 тисячах журналів. Для пошуку матеріалів згідно теми кваліфікаційної роботи мною було здійснено пошук з ключовими словами «Alzheimer disease neural network», що зображено на рисунку 1.3. Було знайдено близько 7 тисяч статей, які корелюються з темою дослідження, проте для детальнішого аналізу потрібно відфільтрувати результати пошуку, наприклад шукати лише актуальні статі, статі з відкритим доступом, або ті, що мають найбільше цитувань.




Рисунок 1.3 – Результат пошуку наукових статей у базі Scopus

За допомогою інструментів аналізу Scopus можна візуалізувати різного виду графіки, що містять важливу інформацію для подальшого дослідження теми. Проаналізувавши рисунок 1.4, де наведено кількість виданих статей за роками, можна зробити висновок про те, що тема є досить актуальною, так як кількість публікацій стрімко зростає кожного року, що означає підвищену цікавість від науковців та дослідників.




Рисунок 1.4 – Графік виданих документів по роках

Ще один важливий графік наведено на рисунку 1.5. На ньому можна побачити кількість опублікованих статей по країнах, що зможе допомогти зробити

висновок про цікавість теми дослідження по країнах. Зокрема можна побачити, що найбільше статей є опубліковано в США, Китаї та Індії. Це може означати про велику кількість дослідників в цих країнах, які розвивають дослідження хвороби Альцгеймера.




Рисунок 1.5 – Графік публікацій по країнах

Здійснивши пошук наукових статей мною було обрано декілька з них для якісного аналізу. Далі буде коротко розкрито зміст кожної з статей.

Нещодавні дослідження продемонстрували ефективність нейронних мереж у діагностиці хвороби Альцгеймера шляхом вилучення ієрархічних ознак з даних нейровізуалізації. Автори статті [9] застосували нейронні мережі для класифікації декількох стадій хвороби Альцгеймера, використовуючи дані MPT з набору даних ADNI, досягнувши багатообіцяючих результатів у вилученні ознак і точності класифікації.

Аналогічно, автор статті [10] підкреслив здатність згорткової нейронної мережі добре розрізняти хворобу Альцгеймера і легкі когнітивні порушення (MCI), що вказує на потенціал цих моделей в клінічних умовах.

Згідно із авторами статті [11] гнучкість моделей глибинного навчання дозволяє перенавчатися на нових даних, що має вирішальне значення для адаптації до мінливих діагностичних критеріїв і демографічних характеристик пацієнтів.

Стаття [12] пропонує важливий і новаторський підхід до використання глибинного навчання для діагностики хвороби Альцгеймера. Автори успішно продемонстрували, як об'єднання задач класифікації та регресії може сприяти покращенню точності діагностики та прогнозування когнітивного стану пацієнтів. Досягнуті високі показники точності та зменшення середньої абсолютної помилки свідчать про ефективність запропонованого підходу, що робить його конкурентоспроможним у порівнянні з сучасними методами. Проте дана модель сильно покладається на якість і доступність багатоканальних даних. У реальних клінічних умовах такі дані можуть бути неповними або недоступними.

У статті [13] автори представили підхід, який базується на архітектурі Siamese convolutional neural network (SCNN) для багатокласової класифікації стадій ХА. Ця архітектура дозволяє ефективно обробляти схожість між зображеннями мозку, що є важливим для класифікації між різними стадіями хвороби. Автори використали MRI-зображення та представили підхід, який мінімізує проблему дисбалансу даних через механізми подібності, вбудовані в Siamese-архітектуру.

Стаття [14] є цікавою і новаторською роботою, яка досліджує використання згорткових автокодерів для вивчення структури хвороби Альцгеймера. Автори пропонують підхід, який спрямований на виявлення прихованих патернів у даних для поліпшення розуміння прогресування хвороби. Автокодери дозволяють ефективно знижувати вимірність даних і виділяти ключові характеристики без втрати важливої інформації, що робить цей підхід потужним інструментом для аналізу медичних зображень, зокрема МРТ. Підхід може бути адаптований для аналізу інших захворювань, що відкриває нові можливості для досліджень у галузі біомедичної інформатики.

Авторами статті [15] було доведено, що об'єднання даних мультимодальних зображень значно підвищує ефективність діагностики. Методи, що поєднують МРТ і ПЕТ-зображення, дають більш повне уявлення про структурні та функціональні зміни мозку, пов'язані з хворобою Альцгеймера. Зокрема вони запропонували ансамбль щільно пов'язаних CNN для діагностики хвороби Альцгеймера, продемонструвавши переваги використання декількох способів

візуалізації для підвищення точності діагностики. Цей мультимодальний підхід підтримується висновками автора [16], який підкреслив важливість інтеграції різних типів даних для вирішення складнощів діагностики хвороби Альцгеймера.

Окрім згорткових нейронних мереж, інші архітектури ШІ, такі як мережі з довгою короткочасною пам'яттю (LSTM), були досліджені для прогнозування прогресування хвороби Альцгеймера. Мережі LSTM, які призначені для фіксації часових залежностей у даних, були використані авторами статті [17] для моделювання прогресування когнітивного зниження з часом, надаючи цінну інформацію про прогресування хвороби Альцгеймера.

Роль глибинного навчання в автоматизації аналізу даних нейровізуалізації важко переоцінити. Традиційні методи діагностики часто покладаються на суб'єктивну інтерпретацію результатів візуалізації, що може призвести до варіативності діагнозів. На противагу цьому, алгоритми глибинного навчання, що обговорюються авторами [18], пропонують систематичну та об'єктивну основу для аналізу функціональних даних МРТ, тим самим підвищуючи діагностичну точність і ефективність. Крім того, використання залишкових нейронних мереж та інших передових архітектур полегшило класифікацію різних стадій хвороби Альцгеймера.

Застосування графових нейронних мереж (GNN) також стало перспективним напрямком для діагностики хвороби Альцгеймера. Автори [19] представили підхід на основі GNN, який включає дані нейронної мережі та клінічну інформацію, що підвищує прогностичні можливості традиційних моделей. Ця інноваційна методологія підкреслює важливість інтеграції різноманітних джерел даних для покращення результатів діагностики.

Автори статті [20] запропонували підхід трансферного навчання, для ранньої діагностики ХА. Автори успішно застосували сучасні алгоритми для обробки МРТ-зображень, демонструючи переваги трансферного навчання у задачах з обмеженою кількістю даних. Використання трансферного навчання дозволяє адаптувати попередньо натреновані моделі до задачі діагностики ХА. Цей підхід є дуже ефективним, особливо в умовах обмеженого обсягу медичних даних. Стаття

наголошує на необхідності раннього виявлення хвороби Альцгеймера, що має ключове значення для своєчасного лікування. Використання МРТ-зображень у поєднанні з трансферним навчанням підвищує ймовірність успішної діагностики на початкових стадіях. Трансферне навчання зменшує обчислювальну складність і ресурси, необхідні для навчання моделі з нуля, що робить метод доступним для впровадження в клінічну практику.

Стаття [21] пропонує новий підхід до діагностики хвороби Альцгеймера використовуючи багатофакторний аналіз даних з різних джерел. Автори зосередилися на комбінації біомаркерів, що включають біомаркери спинномозкової рідини, МРТ-зображення та результати ПЕТ. Використання декількох джерел біомаркерів демонструє сильний підхід до врахування різних аспектів прогресування ХА. Це дозволяє покращити точність класифікації порівняно з однобіомаркерними підходами. Запропонований підхід має значення для клінічної практики, оскільки він спрямований на інтеграцію доступних даних для покращення діагностики та прогнозування хвороби Альцгеймера. Стаття демонструє, що комбінування біомаркерів забезпечує вищу точність у класифікації ХА та передбаченні когнітивного стану порівняно з використанням окремих типів даних. Це підтверджує важливість багатофакторного підходу.

У статті [22] представляється інноваційний підхід до виявлення та прогнозування хвороби Альцгеймера за допомогою багат шарового мультимодального моделювання та пояснюваного штучного інтелекту. Автори пропонують модель, яка об'єднує різноманітні джерела даних, включаючи біомаркери та зображення мозку, для покращення точності діагностики і прогнозування прогресування захворювання. Використання біомаркерів, зображень МРТ, а також клінічних характеристик дає змогу отримати більш точні та надійні результати порівняно з використанням лише одного джерела даних. Застосування технологій пояснюваного ШІ робить модель більш доступною для медичних працівників, оскільки дозволяє зрозуміти, як саме система приймає рішення. Це важливо для довіри до моделі в реальних клінічних умовах, де необхідно розуміти підстави для кожного прогнозу. Модель має великий потенціал

для впровадження в клінічну практику завдяки її здатності інтегрувати різноманітні дані та забезпечувати зрозумілі, інтерпретовані прогнози. Це може допомогти лікарям ухвалювати більш обґрунтовані рішення щодо лікування та моніторингу пацієнтів.

Стаття [23] пропонує новий підхід до прогнозування та класифікації хвороби Альцгеймера, використовуючи багатоступеневу класифікаційну модель. Автори зосереджені на вдосконаленні методів прогнозування ХА, застосовуючи комбіновані стратегії класифікації для поліпшення точності та надійності результатів, зокрема в контексті медичних зображень і біомаркерів. Використання багатоступеневої класифікації дозволяє розглядати дані на різних етапах ітераційно, що покращує точність результатів. Це дозволяє моделі більш гнучко адаптуватися до складних та неоднорідних наборів даних, що є важливим аспектом при діагностиці ХА. Автори чітко описали методологію та результати, що робить статтю легкою для розуміння.

У статті [24] представляється новаторський підхід до класифікації деменції, використовуючи характеристики сигналів електроенцефалографії (ЕЕГ). Автори запропонували методику, що дозволяє точно класифікувати різні типи деменції, аналізуючи електроенцефалографічні дані, що є важливим кроком у напрямку вдосконалення діагностики когнітивних порушень. Такий підхід дозволяє врахувати різні аспекти мозкової діяльності, що важливо для точного виявлення патологій, пов'язаних із деменцією. Модель здатна виділяти особливості, які важко виявити за допомогою традиційних методів аналізу. Це може значно підвищити точність класифікації та дозволити виявляти деменцію на ранніх стадіях.

Автори [25] проводять систематичний огляд сучасних методів глибинного навчання для автоматичного виявлення хвороби Альцгеймера. У статі розглянуто ключові архітектури, такі як згорткові нейронні мережі (CNN) і рекурентні мережі (RNN), а також підходи, що використовують трансферне навчання. Основна увага приділяється аналізу медичних зображень, включаючи МРТ та ПЕТ. Автори також відзначають високий потенціал цих методів для ранньої діагностики, але наголошують на проблемах із нестачею даних та необхідністю стандартизації.

Стаття [26] пропонує оцінку точності використання транскраніальної магнітної стимуляції (ТМС) для діагностики нейродегенеративних деменцій. Автори детально досліджують можливості ТМС як інструменту для раннього виявлення деменцій, таких як хвороба Альцгеймера та інші види нейродегенеративних захворювань, що є важливим для удосконалення діагностики та розробки нових методів лікування. Це важливе доповнення до традиційних методів діагностики, таких як нейропсихологічні тести або нейровізуалізація, оскільки ТМС може надавати нові можливості для оцінки функціональної активності мозку. Автори надають детальну оцінку точності класифікації, порівнюючи ТМС з іншими методами діагностики. Це дозволяє зробити висновки про ефективність використання ТМС в контексті різних видів деменції, що робить статтю важливою для подальшого розвитку методів діагностики в клінічній практиці.

Стаття [27] досліджує ефективність комбінованого використання методів машинного навчання, таких як градієнтний бустинг та нейронної мережі ResNet-50 для класифікації хвороби Альцгеймера, зокрема з урахуванням медичних зображень і без них. Автори порівнюють ці методи для оцінки їх здатності точно визначати наявність захворювання, що є важливим для ранньої діагностики та подальшого лікування. ResNet-50 дозволяє ефективно працювати з зображеннями МРТ, а градієнтний бустинг додає додаткову потужність для класифікації на основі клінічних ознак. Порівняння двох методів дозволяє зрозуміти, наскільки важливими є зображення для досягнення високої точності класифікації, а також дає можливість оцінити, як добре методи працюють з іншими типами даних. Стаття демонструє хорошу точність класифікації за допомогою поєднання градієнтного бустингу та ResNet-50, що вказує на високу ефективність цього підходу для діагностики хвороби Альцгеймера. Це робить метод перспективним для використання в клінічних умовах.

1.3 Висновки до першого розділу

В першому розділі цієї роботи було проведено огляд хвороби Альцгеймера включно з причинами виникнення, формами хвороби та процесом діагностики даного захворювання. Зокрема було описано процес використання методів штучного інтелекту таких як нейронні мережі для діагностики ХА. Опис використання нейронних мереж в цій сфері також було озвучено на XII науково-технічній конференції «Інформаційні моделі, системи та технології» тези матеріалів якої були опубліковані у відповідному збірнику (див. додаток А).

Окрім цього в даному розділі було проведено аналіз методів діагностики хвороби Альцгеймера з використанням машинного навчання. Після аналізу обраних літературних джерел було зроблено висновок про високий потенціал досліджень на дану тему, так як багато науковців зі всього світу проявляють великий інтерес темі діагностики хвороби Альцгеймера.

2 ОПИС ІНФОРМАЦІЙНОЇ СИСТЕМИ

2.1 Дані та їх аугментація


Вибір відповідного набору даних для діагностики хвороби Альцгеймера є важливим етапом розробки інформаційної системи. Беручи до уваги результати аналітичного огляду літературних джерел можна дійти висновку, що МРТ головного мозку є найнадійнішими та водночас найефективнішими даними, які можуть використовуватися для діагностики ХА. Саме тому було вирішено знайти набір даних, який містить зображення МРТ для подальшого тренування нейронної мережі.

Для того, щоб обрати найкращий набір даних потрібно врахувати декілька важливих факторів. Якість зображень повинна мати високу роздільну здатність для збереження дрібних деталей мозку. Дані повинні супроводжуватися чіткою інформацією про стадію хвороби. Набір має містити зображення пацієнтів на різних етапах хвороби, а також здорових людей для порівняння. Набір повинен мати не менше ніж 1000 зображень для навчання нейронної мережі.

Проаналізувавши бази даних з відкритим доступом, я знайшов набір даних, який містить зображення чотирьох груп пацієнтів з діагнозом хвороби Альцгеймера, який зображений на рисунку 2.1.

Alzheimer's Dataset (4 class of Images)

Images of MRI Segmentation



About this directory

Dataset consists of two files - Training and Testing both containing a total of around ~5000 images each

📈 Activity Overview

DATASET STATS

VIEWS

173634

DOWNLOADS

18585

DOWNLOAD PER VIEW RATIO

0.11

TOTAL UNIQUE CONTRIBUTORS

102

Downloads ▾




Рисунок 2.1 – Набір даних «Alzheimer's Dataset»

Alzheimer's Dataset [28] налічує більш ніж п'ять тисяч зображень МРТ головного мозку пацієнтів, які поділені на 4 групи, а саме:

Non AD – відсутність ХА

Very Mild AD – дуже легка форма ХА

Mild AD – легка форма ХА

Moderate AD – ускладнена форма ХА

Даний набір даних містить всю необхідну інформацію, яка може використовуватися для навчання нейронної мережі. Серед переваг цього набору є наявність декількох класів пацієнтів, а також велика кількість даних, що стане вагомим для тренування нейронної мережі. Також варто відмітити інтерес дослідників до цього набору даних, так як його було завантажено більш ніж 18 тисяч разів, що свідчить про актуальність даного датасету.

Для точніших результатів діагностики проводиться аугментація даних [29]. Аугментація – це техніка штучного збільшення обсягу навчальної вибірки шляхом модифікації існуючих даних, щоб створити нові варіації. Вона широко використовується для покращення навчання моделей, особливо у випадках, коли обсяг оригінальних даних обмежений. Найпопулярнішими є такі способи аугментації зображень:

- Додавання шуму
- Масштабування
- Відображення зображення по горизонталі або вертикалі
- Поворот зображення
- Вирізання частини зображення
- Маніпуляції з кольором

Аугментація забезпечує моделі доступ до більшої кількості варіантів даних, що допомагає їй краще узагальнювати закономірності, тобто підвищує різноманітність даних. Окрім цього вона допомагає уникнути ситуації, коли модель добре працює на тренувальних даних, але погано — на тестових зменшуючи

перенавчання. Різноманітність аугментованих даних підвищує стійкість моделі до шуму та змін у реальних даних. Також використання аугментації дозволяє симулювати реальні варіації, так як у розпізнаванні об'єктів зображення в реальних умовах можуть бути затемненими, повернутими чи розмитими. Аугментація навчає модель ефективно працювати в таких ситуаціях, що є критично важливим для медичних зображень, зокрема МРТ головного мозку.

Параметри аугментації слід обирати згідно особливостей вхідних даних. Для медичних зображень важливо зберегти форми, тому доцільно застосовувати масштабування, зміну яскравості та інвертування по горизонталі.

На рисунку 2.2 позначено параметри аугментації, які будуть застосовані для підготовки вхідних даних для навчання нейронної мережі.

```
IMG_SIZE = 180  
IMAGE_SIZE = [180, 180]  
DIM = (IMG_SIZE, IMG_SIZE)  
ZOOM = [.99, 1.01]  
BRIGHT_RANGE = [0.8, 1.2]  
HORZ_FLIP = True
```

Рисунок 2.2 – Параметри аугментації

В межах даного дослідження буде використовуватися масштабування, зміна яскравості зображення та інвертування по горизонталі. Саме ці методи аугментації дозволять досягти кращої точності передбачень нейронної мережі при найменшому впливі на оригінальність даних, адже це є критичним у сфері медицини, так як помилка діагностики може стати фатальною.

2.2 Опис методів штучного інтелекту для обробки медичних зображень

Штучний інтелект [30] – це галузь комп'ютерних наук, яка займається створенням систем, що здатні виконувати завдання, які зазвичай виконуються

людьми, так як потребують людського інтелекту. Найпопулярнішими сферами завдань штучного інтелекту є розпізнавання мови, прийняття рішень, виявлення закономірностей та обробка зображень. До основних характеристик ШІ відносять здатність системи покращувати свою продуктивність на основі попереднього досвіду, здатність логічно аналізувати дані та приймати рішення та можливість взаємодіяти з людьми за допомогою природної мови або жестів. Серед сфер застосування ШІ можна виділити медицину, фінанси, технології, транспорт та науку.

Машинне навчання [31] – це підгалузь штучного інтелекту, яка використовується для створення алгоритмів і моделей, які здатні самостійно навчатися на основі даних. Основна ідея машинного навчання полягає у тому, щоб побудувати систему, яка постійно покращує свою ефективність при збільшенні обсягу доступних даних без необхідності втручання. Машинне навчання дозволяє виявити закономірності, будувати прогнози або приймати рішення на основі аналізу даних. Цей метод особливо ефективний для задач, де традиційні програмні підходи складні або недоцільні. Методи машинного навчання широко застосовуються зокрема в сфері медицини, адже вони мають великий потенціал для діагностики захворювань та аналізу медичних даних, таких як зображення МРТ чи КТ.

Глибинне навчання [32] — це підгалузь машинного навчання, яка базується на використанні багатопов'язаних нейронних мереж для навчання моделей на великій кількості даних. Глибинне навчання дозволяє автоматично виявляти складні закономірності в даних, а також дозволяє моделі розпізнавати більш абстрактні та високорівневі характеристики вхідних даних, так як воно включає використання численних шарів нейронних мереж. Глибинне навчання ефективне для задач, які включають класифікацію, регресію, генерацію та інші типи прогнозів. Найпопулярнішими прикладами використання глибинного навчання є розпізнавання зображень, зокрема медичних, та обробка природної мови.

Нейронна мережа [33] – це модель штучного інтелекту, яка натхненна біологічними нейронами головного мозку, що складаються з кількох

взаємопов'язаних шарів: вхідного, прихованих та вихідного. Вхідний шар отримує вхідні дані та передає їх на перший прихований шар. Приховані шари виконують обробку вхідних даних для пошуку закономірностей. Вони складаються з нейронів, що приймають значення від попереднього шару, згодом обробляють їх та передають на наступний шар аж до вихідного. Сам же вихідний шар генерує кінцеві результати в залежності від завдання, яке було поставлене, наприклад категорія класу зображення при класифікації,

Згорткова нейронна мережа (CNN) [34] – це спеціалізований тип нейронної мережі, який призначений для роботи з двовимірні даними, зокрема зображеннями. Цей тип нейронних мереж використовує спеціальну операцію — згортку (convolution), для того щоб виділити важливі ознаки з вхідних зображень або даних. Згортка дозволяє ефективно виявляти закономірності в зображеннях оскільки CNN використовує фільтри, які можуть обробляти зображення незалежно від їхнього положення. Використання фільтрів також дозволяє значно зменшити кількість параметрів, які треба навчати, що економить багато ресурсів. Найтиповішими прикладами використання CNN є розпізнавання об'єктів на зображеннях, аналіз медичних зображень та обробка відео.

Згортковий шар (convolutional layer) – це основний елемент згорткових нейронних мережах, а також найбільш важливий елемент для обробки та аналізу двовимірних даних, таких як зображення, відео та сигнали. Згорткові шари дозволяють мережі автоматично навчатися важливих ознак без необхідності попереднього ручного виділення ознак. Кожен згортковий шар складається з фільтру, операції згортки, суворості, доповнення та активаційної функції.

Фільтр — це невелика матриця, яка застосовується до вхідних даних для виявлення ключових ознак. Здебільшого фільтр використовується для виявлення країв, вертикальних чи горизонтальних ліній, текстур, чи патернів. Розмір фільтра зазвичай обираються значно менший за розмір вхідного зображення для того щоб вони могли рухатися по зображенню, виконуючи операцію згортки – множення елементів фільтра на відповідні елементи зображення та сумування результатів

Штучний нейрон є основною обчислювальною одиницею нейронної мережі,

який моделює поведінку біологічного нейрона. Хоча штучні нейрони є значно спрощеними, їх будова дозволяє виконувати складні обчислення через комбінацію простих елементів. Штучний нейрон отримує кілька вхідних сигналів від нейронів попереднього шару або від зовнішнього джерела (наприклад, сирих даних, таких як пікселі зображення або ознаки вектора). В задачі класифікації зображень [35-36], вхідні значення можуть бути пікселями зображення, де кожен піксель є числом, що представляє інтенсивність кольору.

Кожен вхідний сигнал множиться на певний коефіцієнт — вагу. Вага відображає важливість кожного вхідного значення для конкретного нейрона. В процесі навчання мережі ці ваги коригуються для досягнення максимально точної роботи нейрона. Якщо вхід є значущим для вирішення завдання, відповідна йому вага буде великою; якщо вхід менш важливий, вага буде меншою або навіть близькою до нуля.

Зсув додається до зваженої суми входів перед застосуванням активаційної функції. Це дозволяє моделі краще адаптуватися до різних умов, навіть якщо всі вхідні сигнали дорівнюють нулю. Зсув забезпечує можливість зміщувати функцію активації вліво або вправо, що збільшує гнучкість нейрона.

Після обчислення зваженої суми входів і зсуву, результат проходить через активаційну функцію, яка визначає, чи "активується" нейрон (тобто, передасть сигнал далі). Активаційна функція також робить поведінку нейронної мережі нелінійною, що дозволяє моделювати складні зв'язки між входами і виходами.

На рисунку 2.3 наведено опис шарів нейронної мережі, що застосовується для діагностики хвороби Альцгеймера з використанням нейронних мереж шляхом аналізу знімків МРТ головного мозку.

Спершу на вхід система отримує зображення, що розбите на пікселі. На першому рівні нейронної мережі визначаються значення пікселів. Згодом, на другому рівні, визначаються контури. На третьому рівні визначаються комбінації контурів, а на четвертому — особливості. Останній рівень визначає комбінації особливостей, що дає змогу визначити прогнозований клас, тобто діагноз пацієнта.




Рисунок 2.3 – Опис шарів нейронної мережі для визначення діагнозу хвороби Альцгеймера

Процес роботи нейрона:

1. Отримання вхідних сигналів. Штучний нейрон отримує значення, які можуть надходити як від інших нейронів (в прихованих або вихідних шарах), так і безпосередньо з вхідного шару (наприклад, пікселі зображення або інші дані).

2. Зважування вхідних сигналів. Кожен вхід множиться на свою вагу, що визначає його значимість для нейрона.

3. Додавання зсуву. До зваженої суми входів додається значення зсуву, щоб забезпечити гнучкість моделі та її здатність до адаптації.

4. Обчислення виходу нейрона. Вихідний сигнал нейрона обчислюється за допомогою активаційної функції.

Під час навчання нейронної мережі ваги та зсув оновлюються для того, щоб мінімізувати помилку мережі. Використовуючи алгоритми, як-от зворотне поширення помилки (backpropagation), нейрон налаштовує свої параметри, щоб покращити точність прогнозів.

Таким чином, штучний нейрон є простою, але потужною обчислювальною

одиницею, що через багат шарову структуру та навчання дозволяє створювати складні моделі для розв'язання різноманітних задач.

Шари нейронної мережі є ключовою структурною одиницею, що визначає, як інформація проходить і обробляється всередині моделі. Кожен шар складається з набору штучних нейронів, які пов'язані між собою. В залежності від типу шару, мережа може виконувати різні типи обробки даних.

Нейронна мережа зазвичай складається з трьох основних типів шарів:

1. Вхідний шар (Input Layer) – це перший шар, через який дані потрапляють у нейронну мережу. Він не виконує жодних обчислень, а лише передає дані до прихованих шарів. Кількість нейронів у ньому відповідає кількості ознак або входів, які надходять до мережі. Якщо це зображення 180×180 пікселів, у вхідному шарі буде 32400 нейрони (180×180). Оскільки цей шар не виконує обчислення, він не має активаційної функції. Він просто передає дані далі.

2. Приховані шари (Hidden Layers) – це основні обчислювальні шари нейронної мережі. Вони обробляють вхідні дані та виявляють приховані закономірності і залежності. Кількість прихованих шарів може бути різною. Простій мережі може бути достатньо одного прихованого шару, тоді як для складних завдань, таких як обробка зображень, можуть знадобитися десятки або сотні прихованих шарів. Якщо кількість прихованих шарів більше одного, мережа називається глибинною нейронною мережею.

Кількість нейронів у прихованих шарах – це гіперпараметр, який визначається експериментально. Занадто велика кількість нейронів може призвести до перенавчання (overfitting), а надто мала — до поганого навчання. Кожен прихований шар виконує зважену суму входів з попереднього шару, застосовує активаційну функцію, а потім передає результат наступному шару. Це дозволяє мережі моделювати складні й нелінійні зв'язки між вхідними даними.

3. Вихідний шар (Output Layer) – це останній шар у мережі, який генерує кінцевий результат. Він може містити один або кілька нейронів залежно від типу задачі. Для задач класифікації існує два типи активаційних функцій у вихідному шарі: Softmax та Sigmoid

Softmax використовується для багатокласової класифікації. Він перетворює вихідні значення в ймовірності, що сумуються до 1, де кожен нейрон видає ймовірність для певного класу. Softmax розраховується за формулою:

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (2.1)$$

де: z_i – вихід нейрона для i -го класу,

e – експоненційна функція,

$\sum_{j=1}^n e^{z_j}$ – сума експонент всіх виходів для всіх класів j .

Sigmoid використовується для бінарної класифікації, повертає ймовірність, що вихід належить до одного з двох класів. Sigmoid є нелінійною активаційною функцією, яка переводить значення в діапазон від 0 до 1. Розраховується за формулою:

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad (2.2)$$

де: z – вхідне значення.

Процес навчання нейронної мережі полягає в налаштуванні параметрів (ваг та зміщень нейронів) так, щоб мережа могла правильно передбачати результати для нових даних на основі прикладів, що їй надані під час навчання. Метою навчання є мінімізація помилки між передбаченим виходом мережі та реальним бажаним результатом. Цей процес зазвичай реалізується через метод оптимізації, який використовує градієнтний спуск і алгоритм зворотного поширення помилки (backpropagation).

Оптимізація в контексті нейронних мереж — це процес налаштування ваг та параметрів мережі з метою мінімізації функції втрат (loss function) та покращення продуктивності моделі на нових, невідомих даних. Оптимізація є критично важливою для навчання нейронних мереж і включає використання різних алгоритмів і технік.

Функція втрат вимірює, наскільки добре модель передбачає результати на основі вхідних даних. Вона порівнює передбачене значення з фактичним

(правильним) значенням і генерує числове значення, яке потрібно зменшити під час навчання. Різні задачі вимагають використання різних функцій втрат. Для задач класифікації, коли потрібно визначити клас зображення найчастіше використовується перехресна ентропія (Categorical Cross-Entropy)

Алгоритми оптимізації визначають, як змінюються ваги нейронної мережі, щоб зменшити функцію втрат. Декілька найпоширеніших алгоритмів оптимізації:

Гرادієнтний спуск (Gradient Descent) [37]: Це основний алгоритм оптимізації, який оновлює ваги на основі градієнта функції втрат. Формула оновлення ваги виглядає так:

Стохастичний градієнтний спуск (Stochastic Gradient Descent, SGD) [38-40]: На відміну від класичного градієнтного спуску, який обчислює градієнт на всьому наборі даних, SGD використовує лише одну вибірку або малу партію (mini-batch) для обчислення градієнта. Це дозволяє швидше оновлювати ваги.

AdaGrad: Адаптує швидкість навчання для кожного параметра окремо, зменшуючи швидкість для частіше оновлюваних ваг.

RMSProp: Подібний до AdaGrad, але використовує експоненційне згладжування, щоб уникнути занадто малого значення швидкості навчання.

Adam (Adaptive Moment Estimation) [41]: Поєднує переваги AdaGrad і RMSProp, зберігаючи моменти градієнтів для адаптації швидкості навчання.

Гіперпараметри — це параметри, які потрібно налаштувати до початку навчання. Вони включають:

Швидкість навчання (Learning Rate) – визначає, наскільки сильно потрібно оновлювати ваги в кожній ітерації. Висока швидкість навчання може призвести до нестабільності, а низька — до тривалого навчання.

Розмір партії (Batch Size) – кількість прикладів, що використовуються для обчислення градієнта. Великі партії можуть призвести до точніших градієнтів, але вимагають більше пам'яті.

Кількість епох (Epochs) – кількість разів, коли вся вибірка даних використовується для навчання моделі.

Раннє зупинення (Early Stopping) дозволяє зупинити навчання моделі, коли

продуктивність на валідаційних даних починає погіршуватися, навіть якщо навчальні втрати продовжують зменшуватися.

2.3 Архітектура інформаційної системи

InceptionV3 [42]— це одна з найбільш відомих і потужних архітектур для обробки зображень, яка була розроблена компанією Google в рамках програми Inception для покращення глибинних нейронних мереж. Основна мета Inception V3 — покращення ефективності нейронної мережі шляхом зменшення кількості параметрів. Це досягається за допомогою інноваційного підходу архітектури мережі, що поєднує різні типи операцій згортки для отримання найкращих результатів при мінімальних витратах обчислювальних ресурсів.

В основі Inception V3 лежать модулі Inception (Inception Module), де мережа не просто складається з одного шару згортки, а використовує декілька різних фільтрів з сталими розмірами (1x1, 3x3, 5x5) в одному шарі. Саме це дозволяє мережі ефективно комбінувати різні рівні абстракції ознак в одному шарі, оптимізуючи точність і зменшуючи кількість параметрів. Модулі Inception можуть включати. 1x1 згортка використовується для зменшення розмірності і збереження важливих характеристик. Ця згортка також використовується для зменшення розмірності шарів, що дозволяє зменшити обчислювальну складність і прискорити навчання. 3x3 і 5x5 згортки для виявлення більш складних ознак на різних масштабах. Максимальне підсумовування (max pooling) для зменшення просторових розмірів зображення та виділення найбільш важливих ознак.

Структура моделі Inception V3 наведена на Рис. 2.4. :




Рисунок 2.4 – Структура моделі InceptionV3 [43]

Inception V3 є ефективною у використанні обчислювальних ресурсів. Це особливо важливо для медичних зображень, таких як МРТ, які можуть бути великими за розміром і вимагати великої обчислювальної потужності для обробки. Завдяки поєднанню різних типів фільтрів та адаптивному використанню різних масштабів, Inception V3 може виділяти закономірності на різних рівнях абстракції, що дозволяє точно визначати специфічні ознаки хвороб, такі як зміни в структурі мозку, зокрема атрофію кори головного мозку, у випадку хвороби Альцгеймера.

Inception V3 може досягти високої точності передбачень навіть при обмеженому наборі медичних зображень. Це корисно в медицині, де зазвичай мало наборів даних з доступом до великої кількості відповідних зображень. Inception V3 завдяки своїй здатності виявляти складні патерни може допомогти у виявленні ранніх ознак хвороби Альцгеймера за допомогою зображень МРТ, що дозволяє почати лікування на ранніх стадіях.

Процес тренування нейронної мережі Inception V3 – це важливий етап, який включає кілька кроків, щоб мережа могла ефективно навчатись та виділяти ознаки з вхідних даних, а також оптимізувати свої параметри для точного виконання задачі, такої як класифікація або діагностика.

Перед тренуванням важливо підготувати дані, зокрема пересвідчитись, що всі вони правильно позначені мітками класів, а також застосувати методи аугментації, що були описані вище, для уникнення перенавчання. Попереднє навчання (Transfer Learning) дозволяє використовуватись попередньо навчені ваги

на великому наборі зображень, таких як набір даних ImageNet. Це дозволяє мережі почати з уже налаштованих ваг і лише донавчати її на специфічних зображеннях МРТ головного мозку, що значно зменшує час тренування. Останні шари мережі можуть бути налаштовані або змінені відповідно до конкретного завдання у нашому випадку багатокласової діагностики.

На етапі тренування мережа проходить через цикли в рамках яких дані передаються через мережу, де кожен шар обчислює свою активацію. За допомогою функції втрат обчислюється різниця між передбаченими та реальними значеннями. Для оптимізації ваг мережі виконується зворотний прохід (Backpropagation), під час якого градієнти функції втрат обчислюються та передаються назад через шари мережі. Це дозволяє оновлювати ваги відповідно до розрахованих градієнтів за допомогою вибраного оптимізатора, такого як Adam. Під час тренування також важливо моніторити точність та втрати, щоб зрозуміти наскільки добре навчається модель. Для запобігання перенавчанню можна використовувати методи, такі як раннє зупинення, коли навчання зупиняється, якщо не спостерігається покращення протягом певної кількості епох.

Після того, як мережа була тренувана, важливо оцінити її на тестовому наборі даних. Правильна оцінка результатів допомагає не тільки визначити точність моделі, а й оцінити її здатність до узагальнення на нові дані. Для оцінки використовують метрики [44], що містять в собі інформацію про ефективність моделі в різних аспектах. Кожна метрика являє собою відношення правильних, неправильних та загальних передбачень в залежності від типу метрики. Для оцінки роботи нейронної мережі використовують чотири основні значення:

- Істинно позитивний (True Positive) – кількість правильно класифікованих пацієнтів з ХА
- Хибно позитивний (False Positive) – кількість здорових людей, які помилково були класифіковані як хворі
- Хибно негативний (False Negative) – кількість хворих людей, які помилково були класифіковані як здорові

- Істинно негативний (True Negative) – кількість здорових людей, які були класифіковані як здорові

Метрика recall (чутливість) [45] дозволяє оцінювати правильні позитивні передбачення, тобто людей з діагнозом ХА. Чутливість важлива, оскільки в діагностиці хвороб важливо не пропустити хворих пацієнтів. У разі ХА важливо, щоб модель не пропустила людей, які насправді мають це захворювання. Дана метрика обчислюється за формулою:

$$Recall = \frac{TP}{TP+FN} \quad (2.3)$$

Метрика precision (точність) [46] показує частку правильних позитивних передбачень серед усіх передбачених позитивних прикладів. Високе значення Precision означає, що модель рідко робить помилки, передбачаючи позитивний клас, тобто хворих на ХА. Обчислюється за формулою:

$$Precision = \frac{TP}{TP+FP} \quad (2.4)$$

Метрика F1-Score [47] – це середнє гармонійне між чутливістю та точністю, застосовується тоді, коли і точність і чутливість однаково важливі, зокрема при діагностиці медичних даних. Розраховується за формулою:

$$F1 - Score = \frac{2*recall*precision}{recall+precision} \quad (2.5)$$

AUC-ROC (Area Under the Curve - Receiver Operating Characteristic) [48] – це метрика оцінки якості роботи моделей класифікації, яка вимірює здатність моделі відокремлювати класи. ROC-крива – це графік, що показує співвідношення між чутливістю (TPR) та часткою негативних випадків (FPR), які помилково класифіковані як позитивні. AUC (площа під ROC-кривою) вимірює, наскільки добре модель відрізняє позитивний клас від негативного. Значення AUC варіюється

від 0 до 1, де 1 означає ідеальну класифікацію, а 0.5 — це випадкова класифікація. AUC є надійною метрикою для задач класифікації, оскільки враховує якість моделі на всіх можливих порогах і не залежить від дисбалансу класів. Розраховується за формулою:

$$AUC = \int_0^1 TPR(t) dFPR(t) \quad (2.6)$$

Матриця плутанини (Confusion Matrix) [49] – це структурована таблиця, що показує розподіл TP, TN, FP, FN. Вона використовується для візуалізації результатів класифікації.

		Справжні значення	
		Positive	Negative
Предбачення	Positive	TP	FP
	Negative	FN	TN

Рисунок 2.5 – Матриця відношення метрик TP, TN, FP, FN

Ця матриця дає змогу оцінити кілька метрик, таких як чутливість, специфічність та інші. Матриця плутанини для багатокласової класифікації розширюється, де кожен клас має свої передбачені й справжні значення, а загальна матриця містить кількість помилок для кожної пари класів.

2.4 Висновки до другого розділу

В першій частині цього розділу було описано набір даних, який використовується в цьому дослідженні, а саме набір даних, що містить зображення МРТ головного мозку поділених на 4 класи пацієнтів з різними стадіями захворювання. Також методи аугментації для покращення точності діагностики нейронної мережі, зокрема в цій кваліфікаційній роботі рівня «Магістр» було використано поєднання методів масштабування, змінення яскравості та інвертування зображення.

В другій частині розділу було описано методи штучного інтелекту для обробки медичних зображень, зокрема велика увага приділялась поясненню роботи елементів штучного інтелекту, глибинного навчання, нейронних мереж. Було також описано шари нейронної мережі для діагностики хвороби Альцгеймера та важливі параметри, які використовуються для покращення точності передбачення.

В третій частині було описано архітектуру моделі нейронної мережі Inception V3. Було детально розглянуто основу цієї нейронної мережі, а також процес тренування. Також було описано важливі метрики оцінки точності діагностики такі як recall, precision, F1-score, AUC-ROC та матриця невідповідностей.

3 РОЗРОБКА ТА ТЕСТУВАННЯ СИСТЕМИ

3.1 Тренування нейронної мережі

Тренування нейронної мережі Inception V3 для аналізу МРТ зображень мозку вимагає значних обчислювальних ресурсів, ефективних алгоритмів і зручних інструментів. Python, завдяки своїм фреймворкам та бібліотекам, пропонує широкий спектр інструментів, які спрощують процес побудови, навчання та оцінки глибоких моделей. Вибір цих інструментів є критичним для точності та ефективності діагностики. Python дозволяє швидко створювати моделі завдяки бібліотекам з уже готовими функціями для побудови архітектури, обробки даних і візуалізації результатів. Бібліотеки дозволяють створювати модульні проекти, які можна легко масштабувати залежно від обсягу даних.

Для тренування нейронної мережі Inception V3 потрібно виконати зчитування і підготовку даних. Це можна зробити за допомогою бібліотеки Keras (див лістинг 3.1).

Лістинг 3.1 – Програмний код для зчитування даних

```
train_dir      = Path('/kaggle/input/alzheimer-mri-dataset/Combined
Dataset/train')

filepaths = list(train_dir.glob(r'**/*.jpg'))

labels = list(map(lambda x: os.path.split(os.path.split(x)[0])[1],
filepaths))

filepaths = pd.Series(filepaths, name='Filepath').astype(str)
labels = pd.Series(labels, name='Label')

train_df = pd.concat([filepaths, labels], axis=1)
train_df = train_df.sample(frac=1).reset_index(drop = True)
```

Отримуємо такий результат:

```
Found 5121 files belonging to 4 classes.
Using 4097 files for training.
Found 5121 files belonging to 4 classes.
Using 1024 files for validation.
```

Рисунок 3.1 – Результат зчитування даних

Як бачимо, було знайдено 5121 зображення, які відносяться до 4 класів, а саме Non AD, Very Mild AD, Mild AD та Moderate AD. Далі поділимо зображення на тренувальні та тестові. Зчитанні дані зображені на рисунку 3.2.




Рисунок 3.2 – Зчитані зображення з набору даних

Наступним кроком буде поділ даних на тренувальні та тестові. Поділ даних є критично важливим етапом розробки моделі машинного навчання, адже він забезпечує об'єктивну оцінку продуктивності моделі та запобігає перенавчанню. Здебільшого дані ділять у співвідношенні 80/20, де більшість тренувальних, а меншість тестових даних. Сам поділ можна зробити за допомогою функції `train_test_split` з бібліотеки `Sklearn` вибравши відповідні значення поділу, що описано в лістингу 3.2.

Лістинг 3.2 – Поділ даних на тренувальні та тестові


```

from sklearn.model_selection import train_test_split
train_data, test_data, train_labels, test_labels =
train_test_split(train_data, train_labels, test_size = 0.2,
random_state=42)
train_data, val_data, train_labels, val_labels =
train_test_split(train_data, train_labels, test_size = 0.2,
random_state=42)

```

Наступним кроком буде побудова моделі нейронної мережі Inception V3 за допомогою бібліотеки Tensorflow.Keras (див. лістинг 3.3).

Лістинг 3.3 – Створення моделі нейронної мережі на базі Inception V3

```

from tensorflow.keras.layers import SeparableConv2D,
BatchNormalization, GlobalAveragePooling2D
custom_inception_model = Sequential([
    inception_model,
    Dropout(0.5),
    GlobalAveragePooling2D(),
    Flatten(),
    BatchNormalization(),
    Dense(512, activation='relu'),
    BatchNormalization(),
    Dropout(0.5),
    Dense(256, activation='relu'),
    BatchNormalization(),
    Dropout(0.5),
    Dense(128, activation='relu'),
    BatchNormalization(),
    Dropout(0.5),
    Dense(64, activation='relu'),
    Dropout(0.5),
    BatchNormalization(),
    Dense(4, activation='softmax')
], name = "inception_cnn_model")

```

Далі потрібно вказати метрики, які будуть використовуватися для оцінки роботи моделі. Після цього можна починати тренування моделі (див. лістинг 3.4).

Лістинг 3.4 – Тренування нейронної мережі

```

EPOCHS = 50
METRICS = [tf.keras.metrics.AUC(name='auc'),
            tfa.metrics.F1Score(num_classes=4, name='f1s'),
            keras.metrics.Precision(name='pre'),
            keras.metrics.Recall(name='rec')] CALLBACKS =
[my_callback, rop_callback]
custom_inception_model.compile(optimizer='Adam',

```

```

loss=tf.losses.CategoricalCrossentropy(),
                                metrics=METRICS)
    history = custom_inception_model.fit(train_data, train_labels,
validation_data=(val_data, val_labels), callbacks=CALLBACKS,
epochs=EPOCHS)
    custom_inception_model.save('/kaggle/working/inception_model',
save_format='h5')

```

Далі можна почати аналізувати результати роботи моделі. Для початку візуалізуємо значення метрик впродовж навчання. Для цього створимо графіки, що містять дані як тренувальних, так і тестових даних (див. лістинг 3.5).

Лістинг 3.5 – Візуалізація графіків метрик precision та recall

```

fig, ax = plt.subplots(1, 3, figsize = (30, 5))
ax = ax.ravel()
for i, metric in enumerate(["pre", "rec"]):
    ax[i].plot(history.history[metric])
    ax[i].plot(history.history["val_" + metric])
    ax[i].set_title("Model {}".format(metric))
    ax[i].set_xlabel("Epochs")
    ax[i].set_ylabel(metric)
    ax[i].legend(["train", "test"])

```

Також створиму криву AUC-ROC для візуалізації співвідношення між чутливістю та часткою негативних випадків, які помилково класифіковані як позитивні, адже метрика AUC вимірює, наскільки добре модель відрізняє позитивний клас від негативного (див. лістинг 3.6).

Лістинг 3.6 – Візуалізація кривої AUC-ROC

```

for i in range(n_classes):
    fpr[i], tpr[i], _ = roc_curve(test_labels[:, i], pred_probs[:, i])
    roc_auc[i] = auc(fpr[i], tpr[i])
plt.figure(figsize=(10, 8))
for i in range(n_classes):
    plt.plot(fpr[i], tpr[i], label='Class {} (AUC = {:.2f})'.format(i,
roc_auc[i]))
plt.plot([0, 1], [0, 1], color='navy', linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('ROC Curve for Multi-Class Classification')
plt.legend(loc="lower right")

```

```
plt.show()
for i in range(n_classes):
    print(f"Class {i} AUC: {roc_auc[i]:.2f}")
```

На рисунках 3.3-3.5 наведено графіки метрик створеної моделі, а саме криву AUC-ROC, Precision та Recall.




Рисунок 3.3 – Графік кривої AUC-ROC




Рисунок 3.4 – Графік метрики Precision




Рисунок 3.5 – Графік метрики Recall

З графіків можна побачити плавне покращення значень метрик з кожною новою епохою, починаючи з 10 епохи. Графіки є здебільшого плавними та зростаючими, що свідчить про правильну побудову моделі нейронної мережі. Запишемо значення метрик в таблицю 3.1.

Таблиця 3.1 - Значення метрик

Метрика	Значення
Recall	0.90
Precision	0.90
F1-Score	0.91
AUC	0.98

Далі створюємо матрицю невідповідностей для візуалізації правильних передбачень створеної мережі (див. лістинг 3.7).

Лістинг 3.7 – Створення матриці невідповідностей

```
pred_ls = np.argmax(pred_labels, axis=1)
test_ls = np.argmax(test_labels, axis=1)
conf_arr = confusion_matrix(test_ls, pred_ls)
plt.figure(figsize=(8, 6), dpi=80, facecolor='w', edgecolor='k')
ax = sns.heatmap(conf_arr, cmap='Greens', annot=True, fmt='d',
xticklabels=CLASSES, yticklabels=CLASSES)
plt.title('Alzheimer\'s Disease Diagnosis')
plt.xlabel('Prediction')
plt.ylabel('Truth')
plt.show(ax)
```

Матриця невідповідностей зображена на рисунку 3.6.




Рисунок 3.6 – Матриця невідповідностей моделі Inception V3

Аналізуючи матрицю невідповідностей можна зробити висновок про те, що створена модель нейронної мережі Inception V3 зробила багато правильних передбачень та взагалі не помилялась з діагнозом для класів Non AD та Very Mild AD, що означає високу точність діагностики ранніх стадій захворювання.

3.2 Аналіз отриманих результатів з використанням Grad-CAM

Оскільки модель Inception V3 показала хороші результати, то було вирішено реалізувати алгоритм Grad-CAM для візуалізації роботи цієї нейронної мережі. Також результати реалізації алгоритму Grad-CAM було озвучено на XII науково-технічній конференції «Інформаційні моделі, системи та технології» тези матеріалів якої були опубліковані у відповідному збірнику (див. додаток А).

Grad-CAM [50] – це описовий метод візуалізації ШІ, який дозволяє подати рішення, прийняті глибокими нейронними мережами, і виявляти, які частини зображення найбільше впливають на класифікацію. Grad-CAM використовується для того, щоб показати, на яких областях зображення фокусується модель, коли робить передбачення. Це особливо корисно для медичних зображень, зокрема

MPT головного мозку при діагностиці таких хвороби Альцгеймера, оскільки це дає змогу лікарям зрозуміти, на що спиралася модель для правильної діагностики. Grad-CAM працює за допомогою градієнтного аналізу, щоб визначити важливість кожного пікселя на зображенні для прийняття рішення в останньому шарі згортки

Поетапний опис роботи методу Grad-CAM:

1. Отримання передбачення. Вхідне зображення пропускається через модель нейронної мережі, щоб отримати прогноз або класову оцінку y^c для цільового класу c .

2. Обчислення градієнтів. Вираховуються градієнти передбачення y^c відносно активацій нейронів у вибраному згортковому шарі. Градієнти показують, наскільки зміни в активаціях шару впливають на вихідний клас.

3. Агрегація градієнтів. Градієнти усереднюються за просторовими вимірами (ширина та висота карти активацій) для кожного фільтра:

$$a_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\delta y^c}{\delta A_{ij}^k} \quad (3.1)$$

де:

a_k^c – вага фільтра k для класу c ;

A_{ij}^k – значення активації фільтра k у позиції (i, j) ;

Z – кількість просторових позицій;

4. Побудова теплової карти. Карти активацій A^k зважуються коефіцієнтами a_k^c і підсумовуються:

$$L_{Grad-CAM}^c = ReLU(\sum_k a_k^c A^k) \quad (3.2)$$

При цьому Функція ReLU використовується, щоб залишити тільки позитивні впливи, ігноруючи негативні

5. Інтерполяція теплової карти. Отримана карта $L_{Grad-CAM}^c$ має розмірність згорткових активацій. Її масштабують до розмірів початкового зображення за допомогою інтерполяції.

6. Накладення на зображення. Теплова карта накладається на вхідне зображення щоб показати області, які найбільше вплинули на прогноз.

Архітектура алгоритму Grad-CAM наведена на рисунку 3.7.




Рисунок 3.7 – Архітектура Grad-CAM

Далі було реалізовано сам алгоритм Grad-CAM, попередньо проаналізувавши документацію [51]. Для найкращої візуалізації роботи алгоритму слід використовувати порівняння діагностики двох класів – здорових та хворих. Інформаційна система отримує дані з передбаченнями нейронної мережі, показує прогноз моделі та за допомогою Grad-CAM візуалізує зони зображення, які мають найбільший вплив на передбачення нейронної мережі. Приклад порівняння МРТ двох пацієнтів зображено на рисунку 3.8.




Рисунок 3.8 – Результат роботи алгоритму Grad-CAM

Проаналізувавши зображення можна дійсти висновку, що Grad-CAM дозволяє побачити, на які саме області звертала увагу модель під час класифікації, що підвищує прозорість роботи нейромережі. Зображення дозволяють порівняти, як змінюється активація в залежності від класу. Для ускладненої стадії Альцгеймера активовані області більше зосереджені навколо структур, характерних для цієї хвороби, таких як кора головного мозку. Неозброєним оком можна побачити концентрацію червоного кольору на рисунку справа, де діагностується хворий пацієнт. Саме ці червоні зони позначають місця з характеристиками найбільш важливими для передбачення.

3.3 Висновки до третього розділу

В цьому розділі було описано процес тренування нейронної мережі Inception V3, зокрема було покроково проілюстровано весь процес тренування починаючи від підготовки даних і закінчуючи аналізом результатів.

Після навчання моделі було проаналізовано результати та створено візуалізацію метрик оцінки точності – графіки та матрицю невідповідностей. Мережа Inception V3 досягнула хороших результатів діагностики, зокрема

отримано значення метрик: AUC: 0.98, Recall: 0.90, Precision: 0.91, F1-Score: 0.90. Також варто відмітити точність передбачень для пацієнтів з ранньою стадією хвороби.

Останнім пунктом цього розділу була реалізація алгоритму Grad-CAM для візуалізації важливих ділянок для передбачення нейронної мережі. Проаналізувавши результати алгоритму було описано закономірності для визначення важливих зон зображень МРТ головного мозку для діагностики хвороби Альцгеймера.

4 ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ

4.1 Організація робочого місця для користувачів комп'ютерної мережі

Розробка інформаційних систем, зокрема системи для діагностики хвороби Альцгеймера, передбачає інтенсивну роботу за комп'ютером, що може впливати на здоров'я розробників. Саме тому необхідно врахувати аспекти охорони праці для створення безпечних та комфортних умов роботи. Охорона праці та безпека в надзвичайних ситуаціях є фундаментом для забезпечення стабільного функціонування будь-якої організації, включаючи сферу інформаційних технологій. Вони мають безпосередній вплив на здоров'я, життя працівників і надійність виробничих процесів.

Охорона праці спрямована на мінімізацію ризиків виникнення професійних захворювань і травм, які можуть бути спричинені фізичними, хімічними, електричними чи іншими факторами. У сфері інформаційних технологій це особливо важливо, адже тривала робота за комп'ютером може спричиняти навантаження на зір, опорно-руховий апарат і нервову систему.

Робота з комп'ютерною технікою вимагає створення ергономічного робочого місця, що передбачає оптимальну висоту стола, правильне розташування монітора, клавіатури та миші, а також забезпечення комфортного освітлення. Такі заходи дозволяють знизити навантаження на зір, уникнути розвитку тунельного синдрому рук і зменшити напругу в шийному та поперековому відділах хребта.

Існує ряд вимог, які визначають особливості заходів з охорони праці при роботі з комп'ютером. Для забезпечення відповідності цим нормам роботодавець повинен організувати робочі місця згідно з вимогами ергономіки, проводити регулярні інструктажі та медичні огляди працівників. В Україні питання охорони праці при використанні персональних комп'ютерів регламентуються такими документами:

1. Кодекс законів про працю України (КЗпП) — основний закон, що регулює трудові відносини, включаючи охорону праці працівників.

2. Закон України "Про охорону праці" — визначає основні принципи охорони праці, зокрема під час роботи з обладнанням і комп'ютерною технікою.

3. Державні санітарні правила і норми (ДСанПіН 3.3.2.007-98) — встановлюють вимоги до організації робочих місць, зокрема до освітлення, температурного режиму, перерв у роботі та ергономіки для користувачів комп'ютерів.

4. Правила безпечної експлуатації електроустановок споживачів — регулюють безпечне використання електрообладнання, у тому числі комп'ютерів, на робочих місцях.

5. Норми часу безперервної роботи з ПК — наказ Міністерства охорони здоров'я України про обмеження безперервного часу роботи за комп'ютером для різних категорій працівників.

6. ISO 9241 (міжнародний стандарт) — стосується ергономіки програмного забезпечення і техніки, що може бути застосовано в Україні для покращення умов праці.

7. Накази та інструкції підприємств — кожне підприємство може мати свої внутрішні положення щодо роботи з комп'ютерною технікою, що базуються на зазначених нормативно-правових актах.

Організація робочого місця користувачів комп'ютерної мережі вимагає дотримання низки важливих аспектів, які забезпечують комфорт, продуктивність і безпеку під час виконання завдань. Серед них особливе значення мають ергономічні, технічні, санітарно-гігієнічні та інформаційно-технологічні вимоги.

Ергономіка робочого місця орієнтована на створення умов, що сприяють зниженню фізичного та зорового навантаження, а також підвищенню продуктивності. Висота столу та стільця повинна відповідати зросту користувача, забезпечуючи зручну посадку, при якій ноги розташовані під прямим кутом, а руки знаходяться на рівні клавіатури. Стілець повинен бути регульованим по висоті. Монітор має бути розташований на відстані 50-70 см від очей, а його верхній край — на рівні очей, що дозволяє зменшити напруження шії та очей. Також для зменшення навантаження на очі необхідно використовувати монітори з високою

роздільною здатністю та мінімальним рівнем мерехтіння. Клавіатура і миша повинні знаходитися на рівні ліктів, щоб забезпечити нейтральну позицію зап'ясть. Освітлення робочого місця має бути достатнім і рівномірним. Найкраще підходить природне освітлення, проте в разі використання штучного важливо уникати відблисків на екрані монітора. Для цього джерела світла повинні бути спрямовані таким чином, щоб не створювати тіней і відблисків. Неперервний час роботи за комп'ютером не повинен перевищувати 2 годин. Через кожні 1,5–2 години необхідно робити перерви тривалістю 10–15 хвилин.

Основні ергономічні вимоги охорони праці при роботі з комп'ютерною технікою наведені на рисунку 4.1.




Рисунок 4.1 – Схема розміщення працівника на робочому місці для роботи з комп'ютером [52]

Технічне забезпечення робочого місця відіграє вирішальну роль у продуктивності користувача. Комп'ютер повинен відповідати сучасним стандартам і мати достатню потужність для виконання поставлених завдань, зокрема, процесор, обсяг оперативної пам'яті та швидкість зчитування даних мають відповідати вимогам робочого середовища. Периферійні пристрої, такі як клавіатура та миша, повинні мати зручний дизайн для довготривалого використання, а також бути надійними у роботі.

Підключення до комп'ютерної мережі повинно бути стабільним і мати достатню швидкість передачі даних. Використання кабельного або бездротового інтернету залежить від характеру роботи, але обидва варіанти мають забезпечувати безперебійний доступ до мережі.

Санітарно-гігієнічні норми спрямовані на створення безпечних і комфортних умов праці. Робоче місце має бути розташоване в приміщенні з оптимальним мікрокліматом: температура повітря повинна варіюватися в межах 18-22°C, а вологість – 40-60%. Важливою є вентиляція, що забезпечує постійний доступ свіжого повітря. Регулярне прибирання і контроль за чистотою повітря сприяють зниженню ризику виникнення алергічних реакцій або захворювань дихальної системи.

Робоче приміщення повинно мати достатню площу для розташування обладнання та забезпечення свободи рухів. Також необхідно забезпечити акустичний комфорт, мінімізуючи рівень шуму.

Інформаційно-технологічна безпека є важливою складовою організації робочого місця. Для цього необхідно використовувати ліцензійне програмне забезпечення, яке регулярно оновлюється для запобігання вразливостям. Обов'язковим є встановлення антивірусних програм і брандмауерів, що захищають дані від зовнішніх загроз.

Крім того, важливим є забезпечення резервного копіювання даних, що дозволяє уникнути їх втрати в разі збою техніки або інших непередбачених ситуацій. Важливо, щоб доступ до мережі був захищений паролями та іншими засобами аутентифікації для збереження конфіденційності даних.

Дотримання вимог охорони праці дозволяє уникнути травматизму та впливу шкідливих факторів. Регулярний контроль рівня шуму, освітлення, температури та якості повітря сприяє збереженню здоров'я працівників і забезпечує їм комфортні умови для виконання завдань. Забезпечення психофізіологічного комфорту також відіграє важливу роль у профілактиці стресу та професійного вигорання. При дотриманні усіх основних заходів охорони праці можна забезпечити стабільне функціонування будь-якої організації, включаючи сферу інформаційних технологій, адже вони мають безпосередній вплив на здоров'я, життя працівників і надійність виробничих процесів.

Комплексний підхід до організації робочого місця з урахуванням усіх зазначених аспектів є запорукою безпеки, продуктивності та комфорту працівників. Впровадження сучасних рішень та дотримання нормативних вимог охорони праці дозволяє не лише знизити ризики професійних захворювань і підвищити ефективність роботи, але й забезпечити відповідність робочого процесу сучасним стандартам, що є важливим для стабільного розвитку організації.

4.2 Фактори ризику і можливі порушення здоров'я користувачів комп'ютерної мережі

Активне використання комп'ютерних мереж є невід'ємною частиною сучасного життя, що приносить беззаперечні переваги, але водночас створює ризики для фізичного та психічного здоров'я користувачів. Постійне використання комп'ютерної мережі може призвести до ряду негативних наслідків, якщо не дотримуватись основних принципів безпеки.

Безпека в надзвичайних ситуаціях – це комплекс заходів, спрямованих на запобігання виникненню небезпечних подій, збереження життя та здоров'я працівників, а також мінімізацію збитків для організації. Надзвичайні ситуації можуть бути спричинені як природними факторами, так і техногенними.

Безпека в надзвичайних ситуаціях є важливим аспектом функціонування будь-якого підприємства, включаючи проєкти в галузі інформаційних технологій.

Забезпечення належного рівня підготовленості та реагування на надзвичайні ситуації дозволяє зменшити ризики для життя та здоров'я працівників, а також мінімізувати можливі матеріальні втрати.

Розглянемо основні фактори ризику, їхній вплив на організм і можливі способи зменшення негативного впливу для користувачів комп'ютерної мережі:

Один із ключових ризиків — сидячий спосіб життя, який стає наслідком тривалого перебування за комп'ютером. Малорухливість сприяє розвитку застійних явищ у кровоносній системі, що з часом може призводити до варикозного розширення вен, утворення тромбів та зниження загального тону організму. Тривале сидіння також негативно впливає на хребет і суглоби, сприяючи розвитку остеохондрозу, порушень постави та хронічного болю в спині.

Іншим важливим фактором є напруження органів зору. Користувачі комп'ютерних мереж змушені довго концентрувати увагу на екрані, що викликає перенапруження очних м'язів. Це може спричинити синдром комп'ютерного зору, який проявляється у вигляді сухості очей, почервоніння, печіння, погіршення фокусування. Також тривале використання екранів із низькою якістю зображення або в умовах недостатнього освітлення може з часом погіршити зір.

Не менш значущим є психоемоційне навантаження. Постійне використання комп'ютерних мереж та висока інтенсивність роботи в онлайн-середовищі часто спричиняють емоційному вигоранню, хронічному стресу і розладам сну. Надлишок інформації, необхідність швидкого прийняття рішень і втрата меж між робочим і особистим часом посилюють тривожність і втомлюваність.

Проблеми можуть також виникати через неправильну організацію робочого місця. Якщо монітор розташований занадто високо чи низько, стілець незручний, а клавіатура не відповідає ергономічним стандартам, це може призвести до болю у шиї, плечах, руках і спині. Особливе занепокоєння викликає розвиток зап'ясткового тунельного синдрому, що виникає внаслідок тривалої роботи з мишкою чи клавіатурою.

Також сучасні електронні пристрої генерують електромагнітне випромінювання. Хоча його рівень у межах норми, тривалий контакт із технікою

може викликати суб'єктивний дискомфорт і бути потенційним фактором впливу на здоров'я в довгостроковій перспективі.

Наслідком зазначених факторів ризику є численні порушення здоров'я. Найпоширенішими серед них є офтальмологічні порушення, м'язово-скелетні захворювання та серцево-судинні захворювання.

Органи зору зазнають значного впливу, що проявляється у вигляді синдрому сухого ока, тимчасового погіршення зору та спазму акомодатії. За відсутності своєчасного лікування ці порушення можуть призвести до розвитку міопії чи інших серйозних захворювань очей. Одним з найпоширеніших офтальмологічних порушень, пов'язаних з використанням комп'ютерних технологій, є синдром комп'ютерного зору. Він виникає через тривале фокусування на екрані комп'ютера і супроводжується рядом неприємних симптомів. Сухість очей викликається зниженням частоти моргання під час роботи за комп'ютером, що призводить до недостатнього змащування очної поверхні сльозами. Це може викликати відчуття дискомфорту або печіння. Перенапруження очей може спричинити запалення кон'юнктиви, що призводить до почервоніння очей. Тривале навантаження на очні м'язи може спричинити спазм акомодатії, що тимчасово ускладнює фокусування на віддалених об'єктах. Перенапруження зорових м'язів може викликати головний біль, який часто виникає після тривалого використання комп'ютера.

Довготривала робота за комп'ютером часто призводить до порушень у функціонуванні опорно-рухового апарату. Малорухливий спосіб життя і неправильне сидіння сприяють розвитку захворювань хребта, таких як остеохондроз. Особливо страждають шийний і поперековий відділи хребта, де виникають болі, скутість і порушення рухливості. Неправильне розташування тіла під час роботи, зокрема нахилена спина, підвищує ризик розвитку сколіозу та інших порушень постави. Тривале сидіння в статичній позі може призвести до болю в суглобах, особливо в колінах, ліктях і плечах.

Недостатня фізична активність і тривале сидіння за комп'ютером можуть негативно впливати на серцево-судинну систему. Малорухливий спосіб життя є однією з причин підвищення кров'яного тиску. Тривале сидіння за комп'ютером

без регулярних фізичних перерв може сприяти розвитку гіпертонії тобто високого артеріального тиску. Стрес і фізичне перевантаження через тривале використання комп'ютера можуть викликати порушення серцевого ритму, зокрема тахікардію, або ж прискорене серцебиття. Перебування в сидячій позі протягом тривалого часу порушує нормальний кровообіг, що може призвести до утворення тромбів або розвитку варикозного розширення вен, особливо в ногах.

Активне використання комп'ютерних мереж, особливо в умовах високого інформаційного навантаження, може негативно позначатися на психоемоційному стані користувачів. Постійне перебування в онлайн-середовищі та необхідність швидко реагувати на інформацію можуть спричиняти постійний стрес. Це підвищує рівень тривожності та відчуття перенавантаження. Довготривала робота з комп'ютером без перерв може призвести до вигорання, особливо у людей, чия робота пов'язана з постійним використанням техніки, наприклад, програмістів або аналітиків. Погіршення психоемоційного стану через невідповідний баланс між роботою та відпочинком може призвести до розвитку депресії, апатії, тривожних розладів і навіть соціальної ізоляції. Використання комп'ютера перед сном або тривале сидіння за екраном може впливати на якість сну, зокрема через збудженість, викликану яскравим екраном, або інформаційним перевантаженням.

Щоб зменшити негативний вплив використання комп'ютерних мереж на здоров'я, необхідно вживати комплексних заходів. Перш за все, слід організувати ергономічне робоче місце. Монітор повинен розташовуватись на рівні очей, стілець — мати підтримку для попереку, а клавіатура — знаходитись на комфортній висоті.

Важливо регулярно робити перерви у роботі. Кожні 1.5-2 години слід відволікатись на 10-15 хвилин, щоб виконати вправи для очей або зробити легку розминку для тіла. Це дозволить зняти напругу з очних м'язів і запобігти застійним явищам у кровоносній системі.

Зниження стресу можливе через встановлення чітких меж між роботою та особистим часом. Планування періодів відпочинку, активні прогулянки на свіжому повітрі, фізичні вправи й обмеження часу перед екраном у вільний час сприяють поліпшенню психоемоційного стану.

Також варто використовувати технічні засоби, що зменшують вплив на зір: антивідблискові екрани, спеціальні окуляри для роботи за комп'ютером, програмне забезпечення для зменшення синього випромінювання.

Дотримання цих рекомендацій сприятиме підтриманню гарного самопочуття навіть за умов тривалої роботи з комп'ютерними мережами, забезпечуючи баланс між продуктивністю та здоров'ям.

4.3 Висновок до четвертого розділу

У четвертому розділі кваліфікаційної роботи було проаналізовано та висвітлено важливість дотримання норм охорони праці та заходів безпеки в надзвичайних ситуаціях у рамках проектування інформаційної системи для діагностики хвороби Альцгеймера.

Розділ підкреслив, що забезпечення безпечних умов праці для персоналу, залученого до розробки та експлуатації системи, є невід'ємною складовою ефективного функціонування. Організація робочого середовища відповідно до ергономічних принципів мінімізує ризик професійних захворювань і підвищує продуктивність праці. Також було розглянуто аспекти безпеки, пов'язані з використанням комп'ютерного обладнання та програмного забезпечення.

Врахування викладених рекомендацій під час впровадження інформаційної системи дозволяє створити безпечне середовище як для розробників, так і для користувачів. Ефективна реалізація охорони праці та безпеки в надзвичайних ситуаціях є важливим фактором стабільного та довготривалого функціонування проєкту.

ВИСНОВКИ

В результаті виконання кваліфікаційної роботи рівня «Магістр» досягнуто основної мети дослідження – успішно розроблена інформаційна система для діагностики хвороби Альцгеймера з використанням нейронних мереж.

В першому розділі кваліфікаційної роботи освітнього рівня «Магістр»:

- Проведено огляд хвороби Альцгеймера, включно з причинами, симптомами та потенціалом досліджень.
- Проаналізовано методи діагностики хвороби Альцгеймера з використанням машинного навчання.

В другому розділі кваліфікаційної роботи освітнього рівня «Магістр»:

- Описано ключові аспекти інформаційної системи, зокрема набір даних, методи штучного інтелекту та алгоритми, які використовуються в дослідженні.
- Описано процес підготовки даних для навчання нейронної мережі, а також архітектура моделі Inception V3.

В третьому розділі кваліфікаційної роботи освітнього рівня «Магістр»:

- Побудована модель згорткової нейронної мережі InceptionV3. Описано метрики оцінки точності та покроково проілюстровано процес тренування мережі.
- Проаналізовано результати роботи створеної моделі. Мережа Inception V3 показала високу точність діагностики з отриманими значеннями метрик: Recall: 0.90, Precision: 0.91, F1-Score: 0.90, AUC: 0.98. Дана модель показує високу точність передбачення класів пацієнтів з ранньою стадією захворювання.
- Створено та протестовано алгоритм Grad-CAM для візуалізації важливих ділянок діагностики. Проаналізувавши результати роботи алгоритму було знайдено закономірність діагностики різних класів пацієнтів.

У розділі «Охорона праці та безпека в надзвичайних ситуаціях»:

- Проаналізовано важливість дотримання норм охорони праці та заходів безпеки в надзвичайних ситуаціях у рамках проектування інформаційної системи для діагностики хвороби Альцгеймера. Особливу увагу приділено організації робочого середовища відповідно до ергономічних принципів.

- Розглянуто аспекти безпеки, пов'язані з використанням комп'ютерного обладнання та програмного забезпечення. Зокрема було описано фактори ризику і можливі порушення здоров'я користувачів комп'ютерної мережі.

ПЕРЕЛІК ДЖЕРЕЛ

1. Oishi, K., Fuse, H., Maikusa, N., Fukami, T., & Alzheimer's Disease Neuroimaging Initiative. (2018). Classification of patients with Alzheimer's disease and healthy subjects from MRI brain images using the existence probability of tissue types. *2018 Joint 10th International Conference on Soft Computing and Intelligent Systems (SCIS) and 19th International Symposium on Advanced Intelligent Systems (ISIS)*, 1035-1038. <https://doi.org/10.1109/SCIS-ISIS.2018.00172>
2. Anuradha, G., Jamal, N., & Rafiammal, S. (2017). Detection of dementia in EEG signal using dominant frequency analysis. *2017 IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI)*, 710-714. <https://doi.org/10.1109/ICPCSI.2017.8391806>
3. Liu, J., Tian, X., Lin, H., Li, H.-D., & Pan, Y. (2024). Multi-task learning for Alzheimer's disease diagnosis and mini-mental state examination score prediction. *Big Data Mining and Analytics, 7*(3), 828-842. <https://doi.org/10.26599/BDMA.2024.9020025>
4. Zuo, L. (2022). Comparison between the traditional and computerized cognitive training programs in treating mild cognitive impairment. *2022 2nd International Conference on Electronic Information Engineering and Computer Technology (EIECT)*, 119-124. <https://doi.org/10.1109/EIECT58010.2022.00029>
5. Rahimpour, M., Goffin, K., & Koole, M. (2019). Convolutional neural networks for brain tumor segmentation using different sets of MRI sequences. *2019 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC)*, 1-3. <https://doi.org/10.1109/NSS/MIC42101.2019.9059769>
6. Abuzaid, M. M., Yuvalı, M., & Ozsahin, D. U. (2024). Machine learning classification of patients undergoing abdominal CT scans: Factors affecting imaging quality and radiation exposure. *2024 Advances in Science and Engineering Technology International Conferences (ASET)*, 1-8. <https://doi.org/10.1109/ASET60340.2024.10708642>

7. Pomper, M. G., & Hammoud, D. A. (2004). Positron emission tomography in molecular imaging. *IEEE Engineering in Medicine and Biology Magazine, 23*(4), 28-37. <https://doi.org/10.1109/MEMB.2004.1337947>
8. Scopus. (n.d.). Retrieved from <https://www.scopus.com/>
9. Kadhim, K., Mohamed, F., Sakran, A., Adnan, M., & Salman, G. (2023). Early diagnosis of Alzheimer's disease using convolutional neural network-based MRI. *Malaysian Journal of Fundamental and Applied Sciences, 19*(3), 362-368.
10. Dakdareh, S. (2024). Diagnosis of Alzheimer's disease and mild cognitive impairment using convolutional neural networks. *Journal of Alzheimer's Disease Reports, 8*(1), 317-328.
11. Warren, S., & Moustafa, A. (2022). Functional magnetic resonance imaging, deep learning, and Alzheimer's disease: A systematic review. *Journal of Neuroimaging, 33*(1), 5-18.
12. Liu, M., Zhang, J., Adeli, E., & Shen, D. (2019). Joint classification and regression via deep multi-task multi-channel learning for Alzheimer's disease diagnosis. *IEEE Transactions on Biomedical Engineering, 66*(5), 1195-1206.
13. Mehmood, A., Maqsood, M., Bashir, M., & Shuyuan, Y. (2020). A deep Siamese convolution neural network for multi-class classification of Alzheimer's disease. *Brain Sciences, 10*(2), 84.
14. Martinez-Murcia, F. J., Ortiz, A., Gorriz, J.-M., et al. (2020). Studying the manifold structure of Alzheimer's disease: A deep learning approach using convolutional autoencoders. *IEEE Journal of Biomedical and Health Informatics, 24*(1), 17-26.
15. Wang, H., Shen, Y., Wang, S., Xiao, T., Deng, L., Wang, X., ... & Zhao, X. (2019). Ensemble of 3D densely connected convolutional network for diagnosis of mild cognitive impairment and Alzheimer's disease. *Neurocomputing, 333*, 145-156.
16. Zhao, M. (2023). Recent progresses in neural networks for Alzheimer's disease detection. Retrieved from [Publisher Info].
17. Hong, X., Lin, R., Yang, C., Zeng, N., Cai, C., Gou, J., ... & Yang, J. (2019). Predicting Alzheimer's disease using LSTM. *IEEE Access, 7*, 80893-80901.

18. Ramzan, F., Khan, M., Rehmat, A., Iqbal, S., Saba, T., & Mehmood, Z. (2019). A deep learning approach for automated diagnosis and multi-class classification of Alzheimer's disease stages using resting-state fMRI and residual neural networks. **Journal of Medical Systems, 44*(2).*
19. Ju, R., Hu, C., Zhou, P., & Li, Q. (2019). Early diagnosis of Alzheimer's disease based on resting-state brain networks and deep learning. **IEEE/ACM Transactions on Computational Biology and Bioinformatics, 16*(1), 244-257.*
20. Mehmood, A., Yang, S., Feng, Z., et al. (2021). A transfer learning approach for early diagnosis of Alzheimer's disease on MRI images. **Neuroscience, 460*, 43-52.*
21. Gupta, Y., Lama, R. K., & Kwon, G.-R. (2019). Prediction and classification of Alzheimer's disease based on combined features from apolipoprotein-E genotype, cerebrospinal fluid, MR, and FDG-PET imaging biomarkers. **Frontiers in Computational Neuroscience, 13*, 72.*
22. El-Sappagh, S., Alonso, J. M., Islam, S. M. R., et al. (2021). A multilayer multimodal detection and prediction model based on explainable artificial intelligence for Alzheimer's disease. **Scientific Reports, 11*(1), 2660.*
23. Kruthika, K. R., Rajeswari, & Maheshappa, H. D. (2019). Multistage classifier-based approach for Alzheimer's disease prediction and retrieval. **Informatics in Medicine Unlocked, 14*, 34-42.*
24. Durongbhan, P., Zhao, Y., Chen, L., et al. (2019). A dementia classification framework using frequency and time-frequency features based on EEG signals. **IEEE Transactions on Neural Systems and Rehabilitation Engineering, 27*(5), 826-835.*
25. Chamakuri, R., & Janapana, H. (2024). A systematic review on recent methods on deep learning for automatic detection of Alzheimer's disease. **Medicine in Novel Technology and Devices, 25*, 100343.*
<https://doi.org/10.1016/j.medntd.2024.100343>.
26. Benussi, A., Grassi, M., Palluzzi, F., et al. (2020). Classification accuracy of transcranial magnetic stimulation for the diagnosis of neurodegenerative dementias. **Annals of Neurology, 87*(3), 394–404.* <https://doi.org/10.1002/ana.25680>

27. Fulton, L., Dolezel, D., Harrop, J., et al. (2019). Classification of Alzheimer's disease with and without imagery using gradient boosted machines and ResNet-50. **Brain Sciences*, 9*(9), 212. <https://doi.org/10.3390/brainsci9090212>
28. Alzheimer's dataset (4 classes of images) [Data set]. Retrieved from <https://www.kaggle.com/datasets/marcopinamonti/alzheimer-mri-4-classes-dataset>
29. Padigela, J., Balla, S. S., Akula, P., & Sravani, K. (2023). Comparison of data augmentation techniques for training CNNs to detect pneumonia from chest X-ray images. **2023 International Conference on Computational Intelligence for Information, Security and Communication Applications (CIISCA)**, 35–39. <https://doi.org/10.1109/CIISCA59740.2023.00017>
30. Chen, G., & Yuan, Q. (2021). Application and existing problems of computer network technology in the field of artificial intelligence. **2021 2nd International Conference on Artificial Intelligence and Computer Engineering (ICAICE)**, Hangzhou, China, 139–142. <https://doi.org/10.1109/ICAICE54393.2021.00035>
31. T. R. N., & Gupta, R. (2020). A survey on machine learning approaches and its techniques. **2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)**, Bhopal, India, 1–6. <https://doi.org/10.1109/SCEECS48394.2020.190>
32. Kaloev, M., & Krastev, G. (2021). Experiments focused on exploration in deep reinforcement learning. **2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)**, 351–355. <https://doi.org/10.1109/ISMSIT52890.2021.9604690>
33. Cai, M. (2022). Neural network model structure and node optimization based on mathematical statistics. **2022 Sixth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)**, 623–626. <https://doi.org/10.1109/I-SMAC55078.2022.9987313>
34. Li, H. (2021). Computer network connection enhancement optimization algorithm based on convolutional neural network. **2021 International Conference on*

Networking, Communications and Information Technology (NetCIT)*, 281–284.
<https://doi.org/10.1109/NetCIT54147.2021.00063>

35. Fryz, M., Scherbak, L., Mlynko, B., & Mykhailovych, T. (2023). Linear random process model-based EEG classification using machine learning techniques. *Proceedings of the 1st International Workshop on Computer Information Technologies in Industry 4.0 (CITI 2023)*, 126–132.

36. Stadnyk, M., Fryz, M., Zagorodna, N., Muzh, V., Kochan, R., Nikodem, J., & Hamera, L. (2022). Steady state visual evoked potential classification by modified KNN method. *Procedia Computer Science, 207*, 71–79.

37. Troedsson, E., Carlsson, M., & Wendt, H. (2024). On gradient-based descent algorithms for joint diagonalization of matrices. *2024 32nd European Signal Processing Conference (EUSIPCO)*, 2632–2636.
<https://doi.org/10.23919/EUSIPCO63174.2024.10715124>

38. Бабак, В. П., Куц, Ю. В., Мислович, М. В., Фриз, М. Є., & Щербак, Л. М. (2024). Об'єктно-орієнтована ідентифікація стохастичних шумових сигналів. Київ: Наукова думка. <https://doi.org/10.15407/978-966-00-1883-9>

39. Babak, V., Zaporozhets, A., Kuts, Y., Fryz, M., & Scherbak, L. (2025). Noise signals: Modelling and analyses. Cham: Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-71093-3>

40. Fryz, M., Kharchenko, S., & Scherbak, L. (2023). Ergodicity and mixing of conditional linear random processes in the problems of information signal modelling and analysis. *Proceedings of the 3rd International Workshop on Information Technologies: Theoretical and Applied Problems (ITTAP 2023)*, 382–388.

41. Şen, S. Y., & Özkurt, N. (2020). Convolutional neural network hyperparameter tuning with Adam optimizer for ECG classification. *2020 Innovations in Intelligent Systems and Applications Conference (ASYU)*, 1–6.
<https://doi.org/10.1109/ASYU50717.2020.9259896>

42. Shetty, S. B., Nishith, C. S., Kamath, & Nishani. (2022). Skin disease classification using inceptionV3 model. *2022 International Conference on Artificial

Intelligence and Data Engineering (AIDE)*, 312–315.
<https://doi.org/10.1109/AIDE57180.2022.10059678>

43. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2015). Rethinking the inception architecture for computer vision. *ArXiv*.
<https://arxiv.org/abs/1512.00567>

44. Rodriguez-Cardenas, D. (2024). Beyond accuracy and robustness metrics for large language models for code. *2024 IEEE/ACM 46th International Conference on Software Engineering: Companion Proceedings (ICSE-Companion)*, 159–161.
<https://doi.org/10.1145/3639478.3639792>

45. Bansal, A., Singh, J., Verucchi, M., Caccamo, M., & Sha, L. (2021). Risk ranked recall: Collision safety metric for object detection systems in autonomous vehicles. *2021 10th Mediterranean Conference on Embedded Computing (MECO)*, Budva, Montenegro, 1–4. <https://doi.org/10.1109/MECO52532.2021.9460196>

46. Yadav, P., Sujatha, P., Dhavachelvan, P., & Prasad, K. (2014). Weight-based precision-oriented metrics for multilingual information retrieval system. *2014 IEEE International Conference on Advanced Communications, Control and Computing Technologies (ICACCCT)*, 1114–1119.
<https://doi.org/10.1109/ICACCCT.2014.7019271>

47. Sepúlveda, J., & Velastín, S. A. (2015). F1 score assessment of Gaussian mixture background subtraction algorithms using the MuHAVi dataset. *6th International Conference on Imaging for Crime Prevention and Detection (ICDP-15)*, London, UK, 1–6. <https://doi.org/10.1049/ic.2015.0106>

48. Bahaweres, R. B., & Nuraini, I. K. (2024). Cost-sensitive approach for improving AUC-ROC curve of software defect prediction. *2024 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, Mataram, Indonesia, 178–183.
<https://doi.org/10.1109/ISITIA63062.2024.10668184>

49. Krstinić, D., Šerić, L., & Slapničar, I. (2023). Comments on “MLCM: Multi-Label Confusion Matrix.” *IEEE Access*, 11*, 40692–40697.
<https://doi.org/10.1109/ACCESS.2023.3267672>

50. Selvaraju, R. R., Cogswell, M., Das, A., et al. (2020). Grad-CAM: Visual explanations from deep networks via gradient-based localization. *International Journal of Computer Vision, 128*(2), 336–359. <https://doi.org/10.1007/s11263-019-01228-7>
51. Gildenblat, J. (n.d.). Advanced AI explainability for PyTorch [Software]. Retrieved from <https://github.com/jacobgil/pytorch-grad-cam>
52. Creating perfect ergonomic workspace: Ultimate guide [Website]. Retrieved from <https://ergonomictrends.com/creating-perfect-ergonomic-workspace-ultimate-guide/>

ДОДАТКИ

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ТЕРНОПІЛЬСЬКИЙ НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ
імені ІВАНА ПУЛЮЯ
НАУКОВЕ ТОВАРИСТВО ім. ШЕВЧЕНКА**

МАТЕРІАЛИ

ХІІ НАУКОВО-ТЕХНІЧНОЇ КОНФЕРЕНЦІЇ «ІНФОРМАЦІЙНІ МОДЕЛІ, СИСТЕМИ ТА ТЕХНОЛОГІЇ»



18-19 грудня 2024 року

ТЕРНОПІЛЬ

2024

ПРОГРАМНИЙ КОМІТЕТ

Голова: Приймак Микола – професор кафедри комп'ютерних систем та мереж, д.т.н., професор.

Співголови: Марущак Павло – проректор з наукової роботи, докт. техн. наук, професор.

Баран Ігор – канд. техн. наук, доцент, декан факультету ФІС.

Науковий секретар: Надія Крива – старший викладач.

Члени: Василь Кривень - завідувач кафедри математичних методів в інженерії д.ф.-м.н., професор; Галина Осухівська – завідувач кафедри комп'ютерних систем та мереж, к.т.н., доцент; Микола Карпінський - професор кафедри кібербезпеки, д.т.н., професор; Жанна Баб'як - завідувач кафедри української та іноземних мов, к.пед. н., доцент; Ярослав Литвиненко – професор кафедри комп'ютерних наук, д.т.н., професор; Михайло Петрик - завідувач кафедри програмної інженерії, д.ф.-м.н., професор; Наталія Загородна – завідувач кафедри кібербезпеки, к.т.н., доцент.

ОРГАНІЗАЦІЙНИЙ КОМІТЕТ

Голова: Скоренький Юрій Любомирович – канд. техн. наук, доцент кафедри фізики.

Члени: доцент кафедри комп'ютерних наук, к.т.н. В. Никитюк; доцент кафедри програмної

інженерії, к.т.н. Д. Михалик; доцент кафедри кібербезпеки, к.т.н. М. Стадник; доцент кафедри комп'ютерних систем та мереж, к.т.н. Є. Тиш; ст. викладач Л. Джиджора.

Матеріали XII науково-технічної конфіції «Інформаційні моделі, М34 системи та технології» Тернопільського національного технічного університету імені Івана Пулюя, (Тернопіль, 18–19 грудня 2024 р.). – Тернопіль : Тернопільський національний технічний університет імені Івана Пулюя, 2024.

Адреса оргкомітету: ТНТУ ім. І. Пулюя, м. Тернопіль, вул. Руська, 56, 46001, тел. (0352) 52-41-33, факс (0352) 25-49-83.
E-mail: confis2024@gmail.com

Редагування, оформлення та верстка: Надія Крива

СЕКЦІЇ КОНФЕРЕНЦІЇ, ЯКІ ПРЕДСТВЛЕНІ В ЗБІРНИКУ

- Математичне моделювання
- Інформаційні системи та технології, кібербезпека
- Комп'ютерні системи та мережі
- Програмна інженерія та моделювання складних розподілених систем
- Новітні фізико-технічні та освітні технології

В збірнику надруковано тези доповідей XII науково-технічної конференції «Інформаційні моделі, системи та технології» (Тернопіль, 18–19 грудня 2024 р.) за такими науковими напрямками: математичне моделювання; інформаційні системи та технології, кібербезпека; комп'ютерні системи та мережі; програмна інженерія та моделювання складних розподілених систем; новітні фізико-технічні та освітні технології.

Розрахований на науковців, викладачів та студентів вузів.

За зміст тез та дотримання норм академічної доброчесності відповідальність несе автор.

[Введіть текст тут]

П. В. Пилипів, Т. А. Лечаченко

РИЗИКИ КІБЕРБЕЗПЕКИ NFT-ТЕХНОЛОГІЇ ТА МЕТОДИ ЇХ ВИРІШЕННЯ

P. Pylypiv, T. Lechachenko

SECURITY RISKS OF NFT TECHNOLOGY AND METHODS FOR ADDRESSING THEM

70

В. Поліщук

РОЗРОБКА СИСТЕМИ ВИЯВЛЕННЯ ВТОРГНЕНЬ НА ОСНОВІ АНАЛІЗУ АНОМАЛІЙ У МЕРЕЖЕВому ТРАФІКУ З ВИКОРИСТАННЯМ МАШИННОГО НАВЧАННЯ

V. Polishchuk

DEVELOPMENT OF AN ANOMALY-BASED INTRUSION DETECTION SYSTEM USING MACHINE LEARNING FOR NETWORK TRAFFIC ANALYSIS

71

О. Прокопенко

РОЗРОБКА НАВЧАЛЬНОЇ СИСТЕМИ ДЛЯ ЗБОРУ ПЕРСОНАЛЬНИХ ДАНИХ З ВИКОРИСТАННЯМ ШТУЧНОГО ІНТЕЛЕКТУ ТА СОЦІАЛЬНОЇ ІНЖЕНЕРІЇ

O. Prokopenko

DEVELOPMENT OF A TRAINING SYSTEM FOR COLLECTING PERSONAL DATA USING AI AND SOCIAL ENGINEERING

72

І. Р. Ралік

CRM-СИСТЕМА ДЛЯ АВТОМАТИЗАЦІЇ ТОРГІВЛІ НА ПІДПРИЄМСТВАХ

I. R. Ralik

CRM-SYSTEM FOR RETAIL AUTOMATION AT ENTERPRISES

73

М. Ратишин

РОЗРОБКА ДЕЦЕНТРАЛІЗОВАНОЇ СИСТЕМИ ЕЛЕКТРОННОГО ГОЛОСУВАННЯ НА ОСНОВІ БЛОКЧЕЙНУ

M. Ratyshyn

DEVELOPMENT OF A DECENTRALIZED ELECTRONIC VOTING SYSTEM BASED ON BLOCKCHAIN

74

Д. Ревура, Р. Козак

ІНТЕРПРЕТАЦІЯ СИСТЕМИ ОЦІНКИ ВРАЗЛИВОСТЕЙ, ЯК МЕТОДУ ДЛЯ ОЦІНКИ РИЗИКІВ

D. Revura, R. Kozak

INTERPRETATION OF A VULNERABILITY ASSESSMENT SYSTEM AS A METHOD FOR RISK EVALUATION

75

Я. Роган

ВИКОРИСТАННЯ МЕТОДУ GRAD-CAM ДЛЯ ДІАГНОСТИКИ ХВОРОБИ АЛЬЦГЕЙМЕРА

Ya. Rohan

USE OF THE GRAD-CAM METHOD FOR DIAGNOSIS OF ALZHEIMER'S DISEASE

76

Я. Роган

ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ АНАЛІЗУ МЕДИЧНИХ ЗОБРАЖЕНЬ

Ya. Rohan

USE OF NEURAL NETWORKS FOR MEDICAL IMAGE ANALYSIS

78

М. М. Рокош

ЗАСТОСУВАННЯ ГЕНЕРАТИВНОГО ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ ЗАХИСТУ КОРПОРАТИВНИХ КОМУНІКАЦІЙ

M. Rokosh

APPLICATION OF GENERATIVE ARTIFICIAL INTELLIGENCE FOR THE PROTECTION OF CORPORATE COMMUNICATIONS

79

81

УДК 004.8

Ярослав Роган

(Тернопільський національний технічний університет імені Івана Пулюя)

ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ АНАЛІЗУ МЕДИЧНИХ ЗОБРАЖЕНЬ

Yaroslav Rohan

USE OF NEURAL NETWORKS FOR MEDICAL IMAGE ANALYSIS

Нейронні мережі стали революційним інструментом в аналізі медичних зображень. Їх здатність до автоматичного виділення ознак, навчання на великих обсягах даних та виконання складних завдань робить їх незамінними у сучасній медицині.

Основними застосуваннями нейронних мереж у цій сфері є діагностика захворювань, сегментація зображень, виявлення патологій, класифікація медичних знімків та прогнозування результатів лікування. Наприклад, згорткові нейронні мережі успішно використовуються для аналізу рентгенівських знімків, комп'ютерної томографії (КТ) та магнітно-резонансної томографії (МРТ). Вони демонструють високу точність у виявленні ракових утворень, пошкоджень кісток та інших патологій.

Основні етапи аналізу медичних зображень за допомогою нейронних мереж:

1. **Збір даних.** Медичні зображення отримують із пристроїв візуалізації, таких як МРТ чи КТ. Ці дані можуть бути представлені в різних форматах.
2. **Попередня обробка зображень.** Попередня обробка потрібна для покращення якості зображень та видалення артефактів. Вона включає фільтрацію шумів, контрастну обробку, нормалізацію та сегментацію.
3. **Аналіз зображень.** Спочатку визначаються ознаки зображень, тобто кількісні характеристики, які використовуються для ідентифікації аномалій, наприклад форма, текстура та інтенсивність. Згодом створюються та навчаються моделі нейронних мереж, які шукають закономірності у зображеннях.
4. **Класифікація.** В залежності від завдання може виконувати двоїсту (наявність або відсутність хвороби) або множинну класифікацію (відсутність хвороби, легка стадія, середня, важка)
5. **Валідація та інтерпретація.** Результати аналізу зображень повинні бути перевірені лікарями. Це гарантує, що модель працює коректно, і її висновки мають практичне застосування.

Переваги використання нейронних мереж включають швидкість обробки зображень, можливість обробки великих обсягів даних та високу точність результатів. Крім того, такі системи можуть працювати як інструменти підтримки прийняття рішень, допомагаючи лікарям уникати людських помилок.

З подальшим розвитком методів навчання, доступу до великих баз даних та зростанням обчислювальних можливостей, нейронні мережі зможуть ще ефективніше допомагати у ранній діагностиці захворювань, розробці індивідуалізованих планів лікування та моніторингу стану пацієнтів.

УДК 004.8

Ярослав Роган

(Тернопільський національний технічний університет імені Івана Пулюя)

ВИКОРИСТАННЯ МЕТОДУ GRAD-CAM ДЛЯ ДІАГНОСТИКИ ХВОРОБИ АЛЬЦГЕЙМЕРА

Yaroslav Rohan

USE OF THE GRAD-CAM METHOD FOR DIAGNOSIS OF ALZHEIMER'S DISEASE

Метод Gradient-weighted Class Activation Mapping (Grad-CAM) є сучасним інструментом штучного інтелекту, що дозволяє візуалізувати роботу глибинних нейронних мереж (ГНМ). У контексті медичної діагностики, зокрема діагностики хвороби Альцгеймера, Grad-CAM допомагає виявляти патологічні особливості на медичних зображеннях, таких як МРТ головного мозку.

Діагностика хвороби Альцгеймера базується на аналізі нейродегенеративних змін, що відображаються у вигляді зменшення об'єму кори головного мозку. Grad-CAM додає прозорості, накладаючи теплові карти уваги на вихідні зображення, що показують, які області мали найбільший вплив на прийняте рішення.

Основний алгоритм Grad-CAM полягає у вирахуванні градієнтів виходу моделі по відношенню до активацій на останньому згортковому шарі. Це дозволяє визначити просторову значущість кожного пікселя. У випадку хвороби Альцгеймера Grad-CAM може ідентифікувати зони атрофії які корелюють із ступенем розвитку хвороби. Поетапний опис роботи методу Grad-CAM:

7. **Отримання передбачення.** Вхідне зображення пропускається через модель (наприклад, ResNet, VGG), щоб отримати прогноз або класову оцінку y^c для цільового класу c .
8. **Обчислення градієнтів.** Вираховуються градієнти передбачення y^c відносно активацій нейронів у вибраному згортковому шарі. Градієнти показують, наскільки зміни в активаціях цього шару впливають на вихідний клас.
9. **Агрегація градієнтів.** Градієнти усереднюються за просторовими вимірами (ширина та висота карти активацій) для кожного фільтра:

$$a_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\delta y^c}{\delta A_{ij}^k}$$

де:

a_k^c – вага фільтра k для класу c ;

A_{ij}^k – значення активації фільтра k у позиції (i, j) ;

Z – кількість просторових позицій;

10. **Побудова теплової карти.** Карти активацій A^k зважуються коефіцієнтами a_k^c і підсумовуються:

$$L_{Grad-CAM}^c = ReLU\left(\sum_k a_k^c A^k\right)$$

При цьому Функція ReLU використовується, щоб залишити тільки позитивні впливи, ігноруючи негативні

11. **Інтерполяція теплової карти.** Отримана карта $L_{Grad-CAM}^c$ має розмірність згорткових активацій. Її масштабують до розмірів початкового зображення за допомогою інтерполяції.
12. **Накладення на зображення.** Теплова карта накладається на вхідне зображення щоб показати області, які найбільше вплинули на прогноз.

На рисунку 1 наведено приклад реалізації методу Grad-CAM для діагностики хвороби Альцгеймера:




Рисунок 1. Реалізація методу Grad-CAM

Проаналізувавши рисунок бачимо, що вхідне зображення покривається картою-градієнтом, показуючи на яких ділянках зображення найбільше було зосереджено уваги для винесення діагнозу нейронною мережею. Червоним кольором позначені ділянки, які мають велике значення важливості для передбачення, сині ділянки позначають ділянки, які мають найменше значення важливості. Таким чином ми бачимо відносно яких ділянок мозку робились передбачення про наявний діагноз і його клас. Зокрема можна помітити високу активність в центральній зоні головного мозку, в місці так званих «шлуночків», а також в закінченнях кори мозку, оскільки дані зони надають найбільше інформації про наявність хвороби Альцгеймера та її складність.

Ефективність Grad-CAM для діагностики хвороби Альцгеймера підтверджується кількома ключовими аспектами. По-перше, метод дозволяє лікарям не лише отримувати результат, але й розуміти, чому модель прийняла певне рішення. Це підвищує довіру до системи. По-друге, Grad-CAM може допомогти у виявленні ранніх змін, що складно помітити при візуальному аналізі. Це відкриває можливості для розробки інтерпретованих рішень у сфері діагностики на основі глибокого навчання, забезпечуючи лікарям корисний інструмент для прийняття рішень.