

Вінницький національний технічний університет
Факультет інформаційних електронних систем
Кафедра біомедичної інженерії та оптико-електронних систем

БАКАЛАВРСЬКА КВАЛІФІКАЦІЙНА РОБОТА

на тему:

МЕТОД ОБРОБКИ ТА АНАЛІЗУ МРТ-ЗОБРАЖЕНЬ ДЛЯ ВИЯВЛЕННЯ
ХВОРОБИ АЛЬЦГЕЙМЕРА


Виконав: студент 4 курсу, групи БМІ-206
Спеціальності 163 – «Біомедична інженерія»

Шевчук І.А. 

Керівник: д. ф., ст. викладач

Карась О.В. 


Рецензент: к.т.н., ст. викл. каф. ІКСТ

Макогон В.І. 

18.06.2024

Допущено до захисту

Завідувач кафедри БМІОЕС

 к.т.н. доц. Коваль Л.Г.

« 12 » 06 2024р.

Вінниця ВНТУ - 2024 рік

Вінницький національний технічний університет
Факультет інформаційних електронних систем
Кафедра біомедичної інженерії та оптико-електронних систем
Бакалавр
163 – Біомедична інженерія

ЗАТВЕРДЖУЮ

завідувач кафедри БМІОЕС

к.т.н., доцент

Коваль Л.Г.

« 11 » 03 2024


ЗАВДАННЯ
НА БАКАЛАВРСЬКУ ДИПЛОМНУ РОБОТУ

Шевчуку Івану Анатолійовичу

(прізвище, ім'я, по батькові)

1. Тема проекту (роботи): Метод обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера
керівник проекту (роботи) : д. ф., ст. викладач, Карась О. В.,
затверджені наказом ВНТУ від «11» березня 2024 року №80
2. Строк подання студентом проекту (роботи): 05.06.2023
3. Завдання проекту (роботи): Розробити метод обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера.
4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити): 1. Дослідження поточного стану проблеми; 2. Методи аналізу зображень мрт; 3. Реалізація нейронних мереж; 4. Охорона праці

6. Консультанти розділів проекту (роботи)


Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Спеціальна частина	Карась О. В., д. ф., ст. викладач	 11.03.2024	 05.06.2024
Охорона праці	Дембіцька С.В., д.п.н., професор кафедри БЖ та ПБ	 18.03.2024	 24.05.2024

7. Дата видачі завдання «11» березня 2024р.

КАЛЕНДАРНИЙ ПЛАН


№ з/п	Назва етапів дипломного проекту (роботи)	Строк виконання етапів проекту (роботи)	Примітка
1	Формування та затвердження теми бакалаврської дипломної роботи (БДР)	До 10.03.2024	
2	Виконання спеціальної частини БДР. Перший рубіжний контроль виконання БДР	До 05.04.2024	
3	Виконання спеціальної частини БДР. Другий рубіжний контроль виконання БДР	До 10.05.2024	
4	Виконання розділу «Охорона праці»	До 26.05.2024	
5	Попередній захист БДР	05.06.2024	
6	Нормоконтроль БДР	12.06.2024	
7	Рецензування БДР	18.06.2024	
8	Захист БДР	19.06.2024	

Студент


(підпис)

Шевчук І.А.

Керівник роботи


(підпис)

Карась О. В.

АНОТАЦІЯ

У роботі розглядається важлива проблема класифікації медичних зображень, яка останніми роками набула значного значення в клінічних задачах лікування пацієнтів. Традиційні методи досягли меж своєї ефективності, що робить необхідним впровадження нових підходів. Одним із таких підходів є використання штучних нейронних мереж, зокрема згорткових нейронних мереж, які продемонстрували високий потенціал у розв'язанні різноманітних класифікаційних завдань.

Мета роботи полягає в розробці програмного забезпечення, яке використовує згорткові нейронні мережі для автоматизованого виявлення ранніх стадій хвороби Альцгеймера шляхом аналізу МРТ-зображень мозку пацієнтів.

Для реалізації класифікатора були використані три базові моделі згорткових нейронних мереж: InceptionV3, VGG19 та ResNet50. Отримані результати свідчать, що розроблена система здатна класифікувати хворобу Альцгеймера за МРТ-знімками з точністю 88%.

ABSTRACT

This work addresses the important problem of medical image classification, which has gained significant importance in recent years in clinical patient treatment tasks. Traditional methods have reached their effectiveness limits, making it necessary to implement new approaches. One such approach is the use of artificial neural networks, particularly convolutional neural networks, which have demonstrated high potential in solving various classification tasks.

The aim of this work is to develop software that uses convolutional neural networks for the automated detection of early stages of Alzheimer's disease by analyzing MRI brain images of patients.

To implement the classifier, three basic models of convolutional neural networks were used: InceptionV3, VGG19, and ResNet50. The obtained results indicate that the developed system is capable of classifying Alzheimer's disease from MRI scans with an accuracy of 88%.

СПИСОК УМОВНИХ СКОРОЧЕНЬ ТА ПОЗНАЧЕНЬ

MPT - Магнітно-резонансна томографія

ХА - Хвороба Альцгеймера

ІНМ - Штучна нейронна мережа

ЗНМ - Згорткова нейронна мережа

CNN - Convolutional Neural Network (Згорткова нейронна мережа)

MRI - Magnetic Resonance Imaging (Магнітно-резонансна томографія)

AI - Artificial Intelligence (Штучний інтелект)

ML - Machine Learning (Машинне навчання)

DL - Deep Learning (Глибинне навчання)

TPR - True Positive Rate (Частка істинно позитивних результатів)

FPR - False Positive Rate (Частка хибно позитивних результатів)

ROC - Receiver Operating Characteristic (Крива робочих характеристик приймача)

AUC - Area Under Curve (Площа під кривою)

GPU - Graphics Processing Unit (Графічний процесор)

TPU - Tensor Processing Unit (Тензорний процесор)

RAM - Random Access Memory (Оперативна пам'ять)

ReLU - Rectified Linear Unit (Виправлений лінійний блок)

SGD - Stochastic Gradient Descent (Стохастичний градієнтний спуск)

ADAM - Adaptive Moment Estimation (Адаптивна оцінка моментів)

FC - Fully Connected (Повнозв'язний шар)

SVM - Support Vector Machine (Метод опорних векторів)

PCA - Principal Component Analysis (Аналіз головних компонент)

t-SNE - t-Distributed Stochastic Neighbor Embedding (t-розподілене стохастичне вбудовування сусідів)

DICOM - Digital Imaging and Communications in Medicine (Цифрова обробка та комунікації в медицині)

ROI - Region of Interest (Область інтересу)

FOV - Field of View (Поле зору)

HD - High Definition (Висока роздільна здатність)

CAD - Computer-Aided Diagnosis (Комп'ютерна діагностика)

NLP - Natural Language Processing (Обробка природної мови)

IoU - Intersection over Union (Перетин над об'єднанням)

ЗМІСТ

ВСТУП	4
1 ДОСЛІДЖЕННЯ ПОТОЧНОГО СТАНУ ПРОБЛЕМИ.....	7
1.1 Обговорення актуальної тематики.....	7
1.2 Опис хвороби Альцгеймера.....	11
1.3 Методи визначення хвороби Альцгеймера	14
1.4 Огляд новітніх методів розв'язання	14
1.5 Сформулювання основних задач.....	14
2 МЕТОДИ АНАЛІЗУ ЗОБРАЖЕНЬ МРТ	18
2.1 Використання технології машинного навчання	18
2.2 Використання штучних нейронних систем.....	24
2.3 Використання згорткових моделей нейронних мереж	27
3 РЕАЛІЗАЦІЯ НЕЙРОННИХ МЕРЕЖ.....	30
3.1 Розробка програмного забезпечення та використання бібліотечних рішень	30
3.2 Підготовка тестових даних	37
3.3 Проведення Експериментів.....	37
3.4 Аналіз отриманих результатів.	37
4 ОХОРОНА ПРАЦІ.....	54
4.1. Технічні рішення щодо безпечного виконання роботи	54
4.2. Технічні рішення з гігієни праці та виробничої санітарії.....	58
4.2.1. Мікроклімат	58
4.2.2. Склад повітря робочої зони	59
4.2.3. Виробниче освітлення	60
4.2.4. Виробничий шум.....	61
4.2.5. Виробничі випромінювання.....	62
4.3 Пожежна безпека	63
4.3.1. Технічні рішення системи протипожежного захисту	64
4.3.2. Технічні рішення системи протипожежного захисту	64
ВИСНОВКИ	65
ПЕРЕЛІК ЛІТЕРАТУРИ	68

ДОДАТОК А Фрагменти коду програмного забезпечення.....	73
--	----

ВСТУП

В сучасному світі проблеми пов'язані з діагностикою та лікуванням хвороб стають все більш актуальними. Однією з найпоширеніших та серйозних хвороб є хвороба Альцгеймера, яка впливає на мільйони людей по всьому світу. Ідентифікація та рання діагностика цієї хвороби є ключовими факторами для успішного лікування та управління її проявами. У цьому контексті велике значення має аналіз медичних зображень, зокрема за допомогою магнітно-резонансної томографії (МРТ).

Цей дослід ретельно розглядає актуальні питання, пов'язані з методами обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера. Він спрямований на огляд існуючих методів діагностики, вивчення новітніх технологій машинного навчання та реалізації штучних нейронних мереж для автоматизованої ідентифікації хвороби на ранніх стадіях. Дослідження також включає аналіз та порівняння різних підходів до обробки зображень з метою підвищення точності та ефективності діагностики.

Спрямування Бакалаврської дипломної роботи:

Дослідження методів обробки та аналізу медичних зображень з метою виявлення ранніх ознак хвороби Альцгеймера за допомогою магнітно-резонансної томографії (МРТ).

Об'єкт БДР:

Медичні зображення головного мозку, отримані за допомогою МРТ.

Завдання БДР:

Провести огляд та аналіз існуючих методів діагностики хвороби Альцгеймера.

Вивчити та порівняти різні підходи до обробки медичних зображень, включаючи методи машинного навчання.

Розробити та навчити штучну нейронну мережу для автоматизованого виявлення ранніх ознак хвороби на МРТ-зображеннях головного мозку.

Провести серію експериментів для оцінки точності та ефективності розробленої системи виявлення хвороби.

Отримані результати:

Розроблена система виявлення хвороби Альцгеймера на основі МРТ-зображень головного мозку демонструє точність класифікації до одного з трьох класів на рівні 88%.

1 ДОСЛІДЖЕННЯ ПОТОЧНОГО СТАНУ ПРОБЛЕМИ

1.1 Обговорення актуальної тематики

На сьогоднішній день аналіз медичних зображень, отриманих з використанням КТ, МРТ та ПЕТ, в основному виконується медичними фахівцями, такими як радіологи, рентгенологи та лікарі, які працюють у сфері діагностики. Однак завдяки постійному вдосконаленню медичного обладнання та інструментів збільшується обсяг знань про хвороби та якість діагностики. Останнім часом значно зросла кількість цифрових медичних зображень, які отримуються під час різноманітних обстежень, таких як рентген, ультразвук, ендоскопія та інші. Лікарі використовують ці зображення для діагностики, прогнозування та планування лікування хвороб. Тому класифікація медичних зображень відіграє ключову роль у медичній практиці. Однак лікарі витрачають багато часу і зусиль на виділення та вибір ознак для класифікації, що може бути виснажливим. Також важливо враховувати обмеженість людських ресурсів, оскільки не завжди доступні достатньо кваліфіковані спеціалісти, і лікарі, як і всі, можуть допускати помилки. Сьогодні згорткові нейронні мережі (ЗНМ) стали одним з найефективніших інструментів для аналізу зображень. Вони виявилися більш ефективними, ніж людські експерти, у багатьох завданнях, пов'язаних з класифікацією та розпізнаванням зображень, і медицина не виключення. Застосування ЗНМ у медицині було успішно підтверджено численними дослідженнями. Наприклад, вони використовуються для автоматичної класифікації туберкульозу на рентгені легень, розрізнення мас печінки на КТ-знімках з контрастом та інші. Деякі дослідження показали, що ЗНМ можуть досягати результатів, які зрівняні з експертами у медичній галузі.

На сьогоднішній день, проблема Хвороби Альцгеймера стає все більш актуальною в усьому світі. Це прогресуюче невиліковне неврологічне захворювання мозку, для якого немає ефективного лікування. Отже, раннє виявлення є надзвичайно важливим для зупинення прогресу симптомів. Однак, діагноз на ранніх стадіях часто виявляється важким, а точність діагностики значно залежить від досвіду та кваліфікації медичних фахівців. З цією метою було розроблено кілька комп'ютерних

систем діагностики, які використовували експертні правила протягом 1970-1990-х років. Ці системи використовували вектори ознак з медичних зображень для навчання контрольованих систем, але потребували присутності експертів, що було часом і коштомно. Сучасні дослідники зосереджуються на розробці моделей штучних нейронних мереж для точної діагностики Хвороби Альцгеймера і вже досягли значних успіхів. Наприклад, була розроблена згорткова нейронна мережа під назвою AlzNet для діагностики за допомогою 2D зрізів МРТ з точністю 99,3%. Проте, всі ці моделі потребують подальшого вдосконалення. Отже, застосування штучних нейронних мереж для діагностики Хвороби Альцгеймера широко розвивається та привертає велику увагу. Пошук нових підходів до класифікації і розпізнавання на МРТ знімках за допомогою нейронних мереж залишається актуальною проблемою у медичній галузі.

1.2 Опис хвороби Альцгеймера.

Хвороба Альцгеймера (ХА) є хронічною нейродегенеративною патологією, яка вперше була описана німецьким лікарем Алоїсом Альцгеймером у 1906 році. Цей захворювання пов'язане з послідовною втратою нейронів головного мозку, зокрема в областях гіппокампу та коркової речовини, що викликає різноманітні порушення когнітивних та психічних функцій. Основні причини ХА пов'язані з нагромадженням білкових агрегатів (амілоїду та тау-білка) у мозку, що сприяє запальним процесам та дисфункції мітохондрій. Наразі, докладне розуміння патогенезу ХА ще потребує додаткових досліджень. Хвороба Альцгеймера характеризується трьома основними етапами - раннім (легким), середнім (помірним) і пізнім (важким). Іноді також виокремлюють передклінічний етап і етап помірно-важкої деменції.




Рисунок 1.1 – представляє порівняльне зображення головного мозку особи без відхилень і при ураженні хворобою Альцгеймера.

Учені виокремлюють дві клінічні форми хвороби Альцгеймера: ранній та пізній початок. Хвороба раннього початку, зазвичай, починається в передстарічому віці і характеризується поступовим загостренням розладів пам'яті, інтелектуальних функцій, мовлення, координації рухів та просторової орієнтації. Пізньо початок хвороби, найчастіше, спостерігається у літньому віці і розпочинається з незначних порушень пам'яті та зменшення інтелектуальних здібностей, які поступово призводять до втрати вищих коркових функцій. Крім того, існує атипова форма хвороби, яка поєднує симптоми хвороби Альцгеймера і судинної деменції. Хоча є декілька теорій, що намагаються пояснити причини розвитку хвороби Альцгеймера, це питання залишається відкритим. Фактори ризику захворювання включають повільну депресію, високий артеріальний тиск, низький інтелект, цукровий діабет та інші. Клінічні прояви хвороби включають погіршення пам'яті, уваги, розумових здібностей та здатності формувати і використовувати рухові навички. Серед симптомів можуть бути погіршення запам'ятовування нової та раніше засвоєної інформації, порушення мовлення, рухів і дій, а також порушення сприйняття. Хвороба Альцгеймера класифікується на три основні стадії: ранню, середню і пізню, а також може бути доклінічна стадія і стадія помірно-важкої деменції.

Симптоми хвороби Альцгеймера змінюються залежно від стадії розвитку захворювання. Нижче подані переформульовані ознаки хвороби на кожній стадії:

1. Доклінічна стадія: Початкові ознаки включають зниження інтелектуальної активності, легку забудькуватість, труднощі з визначенням часу та часткову втрату подійної пам'яті.

2. Стадія м'якої деменції: Характеризується порушеннями пам'яті щодо поточних подій, складнощами в хронологічному та географічному орієнтуванні, розумовими труднощами та абстрактним мисленням.

3. Стадія помірної деменції: Пов'язана з втратою пам'яті на події недавнього минулого, залишаються лише спогади про дитинство і молодість. Спостерігаються дезорієнтація у часі та просторі, підвищена тривожність та емоційна нестійкість.

4. Стадія важкої деменції: Супроводжується глибокими порушеннями пам'яті, втратою усвідомлення часу і оточення, втратою ідентичності та здатності до логічних міркувань.

5. Заклучна стадія важкого недоумства: Характеризується повною руйнацією психічної діяльності, серйозними неврологічними порушеннями, епілептичними випадками та іншими фізичними відхиленнями.

На кожному етапі розвитку хвороби можуть спостерігатися агресивність, збудження та інші аномальні поведінкові вияви. Захворювання також призводить до соціальної та професійної дезадаптації. Тривалість від початку симптомів до смерті може становити від 2 до 20 років. Найбільш серйозним наслідком є аспіраційна пневмонія, спричинена вдиханням рідини або їжі в легені.

1.3 Методи визначення хвороби Альцгеймера

Сьогодні для виявлення хвороби Альцгеймера застосовуються нові методи, що перебувають у стадії клінічних досліджень. Один із них - магнітно-резонансна томографія (МРТ), яка використовує принцип магнітного резонансу. У цьому методі пацієнт розміщується в сильному магнітному полі, що абсолютно безпечно за умови відсутності магнітних або металевих імплантатів. Ще один метод - комп'ютерна томографія (КТ), використовує рентгенівську технологію для отримання багатьох 2D рентгенівських знімків, які потім обробляються для створення 3D зображення. КТ не є повністю безпечним через використання рентгенівського випромінювання. Третій метод - позитрон-емісійна томографія (ПЕТ), використовує радіоактивний індикатор низької радіації для виявлення особливих функцій у мозку. МРТ відмінний тим, що не використовує іонізуючого випромінювання, а дозволяє отримувати тривимірні зображення на будь-якій глибині та напрямку. Під час МРТ-сканування відбувається орієнтація протонів у тілі пацієнта за допомогою радіохвиль та прядильних полів. Для візуалізації зображень МРТ при хворобі Альцгеймера використовуються аксіальні та корональні площини сканування. На рисунку 1.2 представлені МРТ-зображення корональної та аксіальної площин мозку здорової людини та людини з ХА.




Рисунок 1.2 – На перших двох зображеннях представлено мозок здорової людини у корональній та аксіальній площинах. На інших двох - мозок людини, яка страждає на хворобу Альцгеймера, відображений у відповідних площинах.

На знімках чітко видно зміни в структурі мозку людини, які є біомаркерами змін. Ці зміни включають атрофію лобкових та теменних частин мозку, а також атрофію мезіальної скроневої частки. Вимірювання ступеня цієї атрофії на основі зображень МРТ вважається надійним показником стану та прогресування хвороби. Атрофія є важливим і постійно прогресуючим показником нейродегенерації, яка відбувається через втрату дендритів і нейронів. Місце втрати мозкової тканини має сильний зв'язок з рівнем когнітивних порушень. Наприклад, атрофія лобкових та теменних ділянок мозку є ключовим маркером хвороби Альцгеймера, і може бути виявлена на МРТ-знімках у площині аксіального сканування. Оцінка атрофії цих ділянок може проводитися за розширенням бічних шлуночків та глибиною коркових борозен на цьому рівні, використовуючи шкалу глобальної коркової атрофії (GCA). На рисунку 1.3 показано атрофію неокортекса та розширення бічних шлуночків на знімку МРТ у площині аксіального сканування.



Рисунок 1.3 – На зображенні МРТ людини з хворобою Альцгеймера видно виділені області, які включають бічні шлуночки, позначені червоним кольором, та неокортекс, позначений синім кольором.

Шкала GCA (Global Cortical Atrophy Scale) - це інструмент для оцінки загальної атрофії кори мозку за допомогою зображень МРТ. Вона дозволяє фахівцям або дослідникам оцінити ступінь атрофії неокортекса (зовнішнього шару кори головного мозку) за певною шкалою. Типова шкала GCA може включати такі ступені атрофії: від відсутності атрофії або мінімальної до важкої атрофії, яка супроводжується значною втратою коркової маси. Цей інструмент стає особливо корисним у діагностиці хвороби Альцгеймера, оскільки атрофія є невід'ємним і прогресуючим проявом нейродегенерації.

1.4 Огляд новітніх методів розв'язання

Щодо аналізу методів класифікації зображень, існують різні підходи, але один з найпоширеніших - класичний метод машинного навчання. Цей метод ґрунтується на використанні статистичних алгоритмів для класифікації зображень на основі попередньо вибраних ознак. Він вимагає визначення певних характеристик зображень, таких як кольорові або текстурні особливості, та застосовує алгоритми, такі як метод опорних векторів або наївний Баєсівський класифікатор, для розпізнавання та класифікації зображень.




Рисунок 1.4 – SVM метод, що розділяє дані за допомогою оптимальної гіперплощини.

Метод опорних векторів (SVM) використовується для класифікації даних на основі оптимальної гіперплощини. Це включає підготовку даних, визначення гіперплощини та класифікацію нових зразків. SVM може ефективно працювати з великими обсягами даних та високорозмірними просторами, але вимагає значних обчислень та може бути чутливим до нерівномірного розподілу класів або наявності шуму. Згорткові нейронні мережі (CNN) також ефективно використовуються для аналізу зображень, використовуючи згорткові та пулінгові шари для виявлення різних рівнів абстракції.

Основний процес роботи згорткової нейронної мережі (CNN) можна узагальнити так:

Згортковий шар: Використовуються фільтри для виявлення локальних особливостей на зображенні, які допомагають визначити границі, форми та текстури.

Функція активації: Після згорткового шару застосовується нелінійна функція, наприклад ReLU, для виявлення нелінійних залежностей в даних.

Пулінговий шар: Зменшує розмір карти ознак, щоб забезпечити інваріантність до малих зміщень об'єктів на зображенні.

Повторення шарів: Згорткові та пулінгові шари можуть повторюватися, щоб виявити більш складні ознаки.

Повнозв'язний шар: Отримана карта ознак перетворюється в одновимірний вектор для класифікації за допомогою повнозв'язного шару.

Функція втрат: Використовується для навчання моделі, оцінюючи різницю між прогнозованими та справжніми значеннями.

Після навчання модель може застосовуватися для класифікації нових зображень, передбачаючи їхню приналежність до одного з класів. Цей опис надає загальне уявлення про роботу згорткової нейронної мережі, а деталі реалізації будуть розглянуті в наступному розділі.

Отже, як і опорні вектори, згорткові нейронні мережі (CNN) є потужними інструментами для різних завдань, таких як класифікація зображень. Однак, у випадку аналізу зображень, особливо з урахуванням їхньої просторової структури та локальних особливостей, CNN є ефективнішим вибором. Вони використовують згорткові шари для розпізнавання різних рівнів абстракції та автоматичного вивчення характеристик зображень, таких як границі, форми та текстури. Однією з переваг CNN є їх здатність автоматично вивчати ознаки, без необхідності вручну вказувати фільтри та особливості для аналізу. Це робить їх більш гнучкими та здатними до адаптації до різних завдань аналізу зображень. Таким чином, для нашої задачі класифікації зображень ми обрали CNN, оскільки вона є потужним інструментом для обробки зображень, здатним автоматично визначати важливі ознаки та використовувати просторову структуру зображення. Використання CNN допоможе нам досягти більш точних результатів класифікації та кращої здатності узагальнення до нових зображень.

1.5 Сформулювання основних задач

Враховуючи значення аналізу МРТ-зображень головного мозку та зростаючий інтерес до використання нейронних мереж у медицині, наша робота спрямована на використання згорткових нейронних мереж для діагностики хвороби Альцгеймера на різних її стадіях. Метою нашого проекту є створення програмного забезпечення, яке використовує згорткові нейронні мережі для ранньої діагностики цієї хвороби за допомогою аналізу МРТ-зображень мозку пацієнтів. Для досягнення цієї мети ми визначили наступні кроки: аналіз сучасного стану проблеми, вивчення існуючих технологій, створення та налаштування штучної нейронної мережі для обробки МРТ-зображень, а також її навчання та тестування.

2 МЕТОДИ АНАЛІЗУ ЗОБРАЖЕНЬ МРТ

2.1 Використання технології машинного навчання

Машинне навчання (МН або ML) - це широкий набір методів штучного інтелекту, які дають комп'ютерам можливість вчитися та покращувати свою продуктивність на основі даних, без прямого програмування. Основна ідея полягає в тому, щоб навчити комп'ютери вирішувати завдання, надаючи їм приклади та дані для навчання замість прямого кодування правил. Алгоритми МН використовують статистичні методи та математичні моделі для виявлення закономірностей та патернів у великих обсягах даних і зроблення прогнозів або прийняття рішень на їх основі. Машинне навчання застосовується в різних галузях, таких як розпізнавання образів, обробка мови, рекомендаційні системи, автономні автомобілі, медична діагностика тощо. Види МН включають контрольоване, неконтрольоване та навчання з підкріпленням, кожен з яких має свої особливості та застосування.

2.2 Використання штучних нейронних систем

Штучна нейронна мережа (ШНМ) - це математична модель, яка намагається імітувати роботу нейронної мережі в мозку. Вона складається зі штучних нейронів, які виконують обчислення та обмін сигналами. Використовується вона в машинному навчанні для розв'язання різних задач, таких як класифікація, регресія, генерація, розпізнавання образів та інші. Нейрон, в свою чергу, є основним будівельним блоком штучної нейронної мережі, який моделює нейрон у живому мозку. Він приймає вхідні сигнали, обчислює їх зважену суму та застосовує нелінійну функцію активації для генерації вихідного сигналу.




Рисунок 2.1 – Математична абстракція нейрона

У відповідності до зображення 2.1: - x_i - це вхідні сигнали; - w_i - це вагові коефіцієнти, що відповідають за силу зв'язку; - b - це зміщення; - f - це нелінійна функція активації. Кожен нейрон має свої вхідні зв'язки, які мають вагу, що відображає силу цих зв'язків. Вхідні дані множаться на ваги, і зважена сума передається функції активації, яка визначає, чи активується нейрон, чи ні. Ці дії можна записати у вигляді наступної формули:

$$y = f(\sum w_i x_i + b), \quad (2.1)$$

Результат, який отримується від нейрона, позначається як y . Функція активації може бути різною, наприклад, сигмоїдальна, ReLU (Rectified Linear Unit), гіперболічний тангенс або інша. На рисунку 2.2 [17] показано кілька таких функцій активації.




Рисунок 2.2 – Активаційні функції

Функції активації у штучних нейронних мережах відповідають за додавання нелінійності до моделі та розв'язання нелінійних завдань. Вони отримують на вході зважену суму вхідних сигналів і генерують вихідний сигнал або активацію, яка передається наступним шарам мережі. Функція сигмоїди перетворює будь-яке дійсне число на діапазон від 0 до 1 і застосовується у бінарній класифікації та ситуаціях, де потрібно отримати ймовірність належності до класу. Функція ReLU повертає 0 для від'ємних значень і саме число для не від'ємних, і використовується в глибоких мережах, оскільки ефективно розв'язує проблему зниклих градієнтів і підвищує швидкість навчання. Функція тангенса гіперболічного перетворює дійсні числа на діапазон від -1 до 1 і корисна для прогнозування від'ємних і позитивних значень в глибоких мережах. Також, важливою є функція активації SoftMax, яка використовується у багатокласовій класифікації, перетворюючи вектор реальних чисел на вектор ймовірностей для кожного класу. Формула для обчислення SoftMax:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{k=1}^K e^{z_k}} \quad (2.2)$$

У формулі для SoftMax: z_i представляє елементи вхідного вектора, які можуть бути будь-якими дійсними числами; e^{z_i} - це стандартна експоненціальна функція, що застосовується до кожного елементу вхідного вектора; $\sum e^{z_k}$ - це сума для

нормалізації, щоб забезпечити, що сума всіх вхідних значень функції буде дорівнювати 1, і кожне значення буде у діапазоні $(0,1)$; K - це кількість класів у мультикласовому класифікаторі.

Штучна нейронна мережа (ШНМ) складається з багатьох нейронів, організованих у шари. Вхідний шар отримує вхідні дані, внутрішні шари обчислюють інтермедіатні репрезентації, а вихідний шар генерує вихідні результати або передає їх наступному шару. Сигнали та ваги передаються через мережу, а ваги оновлюються під час тренування для відповідності певним шаблонам або даним.

Шар нейронів представляє собою групу нейронів, які знаходяться на одному рівні в архітектурі мережі. Кожен нейрон у шарі обчислює ваговану суму вхідних сигналів та застосовує функцію активації для генерації вихідного сигналу.

Основними типами шарів в нейронних мережах є:

1. Вхідний шар: приймає вхідні дані.
2. Приховані шари: обробляють інтермедіатні репрезентації.
3. Вихідний шар: генерує вихідні результати або передає їх наступному шару.




Рисунок 2.3 – 2-шарова нейронна мережа, або мережа з одним прихованим шаром (а), складається з вхідного шару, який приймає дані, та вихідного шару, який генерує вихідні результати. Між цими двома шарами знаходиться прихований шар, де обчислюються інтермедіатні репрезентації. 3-шарова нейронна мережа, або мережа з двома прихованими шарами (б), також має вхідний та вихідний шари, але між ними розташовано два приховані шари, де відбувається обчислення інтермедіатних представлень даних.

У кожному шарі нейронів у мережі існують ваги, які використовуються для

обчислення зваженої суми вхідних сигналів. Ці ваги набуваються в процесі навчання, коли модель оптимізує їх значення для досягнення потрібних вихідних результатів. Шари нейронів служать для розв'язання складних завдань, виконання різних обчислень та створення відповідей на основі вхідних даних.

2.3 Використання згорткових моделей нейронних мереж

Згорткова нейронна мережа (CNN) - це певний тип штучної нейронної мережі, спеціально розроблений для ефективної обробки та аналізу зображень. Вона використовується для автоматичного виявлення та виділення різних місцевих особливостей зображень, використовуючи фільтри або ядра згортки. Розглянемо більш докладно, як працює згорткова нейронна мережа на прикладі простої задачі класифікації зображень, наприклад, розпізнавання хрестиків та нуликів.




Рисунок 2.4 – Зображення вхідних даних

Використання багатошарового персептрона означає, що з вхідного зображення створюється один вектор, який містить інформацію про всі пікселі. Цей вектор потім обробляється шляхом попиксельної обробки. Однак такий підхід призводить до того, що кожен піксель обробляється незалежно від своїх сусідів, що може ускладнити навчання, особливо при роботі з більш складними випадками.




Рисунок 2.5 – Складні випадки

Отже, щоб ефективно розв'язати цю задачу, краще скористатися ЗНМ. Замість того, щоб аналізувати окремі пікселі, ми будемо розглядати фрагменти зображень. Це

підходить краще і дає кращі результати, оскільки уникне втрати інформації і забезпечить більш точні аналізи.




Рисунок 2.6 – Співставлення частин зображення

Отже, яким чином можна розділити вхідне зображення на частинки? Ось де допомагають фільтри, відомі також як ядра. Кожен фільтр є матрицею чисел, яка сканується через вхідні дані шару. Це досягається шляхом обчислення скалярного добутку між фільтром та відповідною областю даних попереднього шару під час процесу згортки.

Отже, як ми можемо поділити вхідне зображення на частинки? Це можливо завдяки фільтрам, також відомим як ядра. Кожен фільтр є матрицею чисел, яка рухається по всьому вхідному зображенню (або карті ознак попереднього шару), обчислюючи скалярний добуток з відповідною областю даних.




Рисунок 2.7 – Виділення ознак за допомогою фільтрів

Як вже зазначалося, архітектура згорткової нейронної мережі складається з різних блоків, таких як шари згортки, шари пулінгу та повністю зв'язані шари.

Зазвичай це включає стек повторюваних шарів згортки та шарів пулінгу, за якими йде один або кілька повністю зв'язаних шарів. Цей процес, коли вхідні дані проходять через ці шари та перетворюються на вихідні дані, називається прямим поширенням. Давайте розглянемо детальніше шар згортки. Він відповідає за вилучення ознак, виконуючи комбінацію лінійних і нелінійних операцій, включаючи операції згортки та функції активації. Операція згортки - це спеціалізований тип лінійної операції, яка використовується для вилучення ознак. Вона застосовується до вхідних даних у вигляді тензорів за допомогою невеликого масиву чисел, який називається ядром.




Рисунок 2.8 – Принцип роботи згортки

В кожній позиції тензора проводиться операція поелементного множення між елементами ядра та вхідним тензором, а потім результати цих множень сумуються. Таким чином, отримується значення у відповідній позиції вихідного тензора, яке відображається як карта ознак (або карта активації).



Рисунок 2.9 – Отримання карти активації

Кожен фільтр у згортковому шарі відповідає певній ознаці об'єкту. Зазвичай використовується набір різних фільтрів з різними параметрами ваги, що дозволяє створювати різноманітні карти ознак. Це означає, що різні фільтри служать для виявлення різних характеристик об'єктів. Операція згортки має чотири основні параметри: розмір ядра (зазвичай 3x3, іноді 5x5 або 7x7), кількість фільтрів, крок (зсув) та заповнення нулями. Кількість фільтрів визначає глибину кінцевих карт ознак об'єктів і може бути налаштована вручну.



Рисунок 2.10 – Результат кількох операцій згортки

З аналізу зображень видно, що використовується певна математична функція для визначення розмірності карти ознак.

$$\frac{N-F}{S} + 1 \quad (2.3)$$

У вищезазначеному описі використовуються терміни:

- N - розмірність вхідного тензора;
- F - розмірність фільтра;
- S - розмір кроку (зсуву).

Операція згортки, описана вище, обмежує центр кожного ядра вхідного тензора та зменшує розміри вихідної карти об'єктів. Для збереження розмірів та дозволу для більшої глибини шарів у моделі використовується метод нульового

заповнення. Це означає, що до вхідного тензора додаються рядки та стовпці нулів, щоб центр ядра міг знаходитись на крайньому зовнішньому елементі. Завдяки нульовому заповненню розміри карти об'єктів залишаються незмінними після кожного шару згортки. Без нульового заповнення кожна наступна карта об'єктів зменшується після операції згортки.




Рисунок 2.11 – Нульове доповнення дає на виході таку саму розмірність як на вході

Після проходження вихідних даних через лінійну операцію, таку як згортка, вони проходять через нелінійну функцію активації. Потім шар об'єднання виконує зниження дискретизації, зменшуючи розмірність карт ознак. Це робиться для досягнення трансляційної інваріантності та зменшення кількості параметрів, які потрібно навчити. Одним з найпоширеніших методів об'єднання є максимальний пулінг. Під час максимального пулінгу витягуються патчі з вхідних карт об'єктів, вибирається максимальне значення у кожному патчі, а решта значень відкидаються. Зазвичай використовується максимальний пулінг з фільтром розміром 2x2 і кроком 2, що зменшує розмірність у площині карт об'єктів у два рази. Глибина карт об'єктів залишається незмінною, відмінно від ширини та висоти.



Рисунок 2.12 – Максимальний пулінг

Після того, як об'єкти виділені згортковими та згортково-пулінговими шарами, їх вихідні карти об'єктів спочатку перетворюються в одновимірний масив чисел, який називається вектором. Потім цей вектор передається в один або кілька повністю пов'язаних шарів, які також відомі як щільні шари. В щільних шарах кожен вхід пов'язаний з кожним виходом за допомогою ваг, які піддаються навчанню. Після створення об'єктів, виділених згортковими та згортково-пулінговими шарами, вони відображаються підмножиною повністю пов'язаних шарів, що приводить до кінцевих вихідних даних мережі, наприклад, ймовірностей для класів в задачах класифікації. Останній повністю пов'язаний шар зазвичай має кількість вихідних вузлів, рівну кількості класів. Після кожного повністю пов'язаного шару використовується нелінійна функція активації, в нашому випадку, згідно попереднього опису - це функція SoftMax.

Навчання згорткової нейронної мережі (ЗНМ) - це процес, під час якого модель "вчиться" розпізнавати патерни та виконувати завдання на основі вхідних даних. Цей процес можна розглядати в кілька кроків:

1. Ініціалізація ваг: На початку навчання ваги ЗНМ ініціалізуються випадковими значеннями.

2. Пряме поширення: Вхідні дані подаються на вхідний шар ЗНМ. Поширюючись вперед через згорткові шари, карти ознак формуються шляхом виконання згортки та активації. Потім вони можуть проходити через шари пулінгу, де розмір карти зменшується, зберігаючи важливі особливості.

3. Обчислення втрат: Вихідні дані з остаточного шару порівнюються з

бажаними вихідними значеннями, що відповідають вхідним даним, для обчислення втрати або помилки моделі.

4. Зворотне поширення помилки: Після обчислення втрати використовується алгоритм зворотного поширення помилки для розповсюдження помилки назад через мережу, щоб визначити, як змінити ваги для зменшення втрати.

5. Оновлення ваг: Загальний градієнт ваг обчислюється, а потім ваги оновлюються з використанням алгоритму оптимізації, такого як стохастичний градієнтний спуск (SGD) або його варіації.

6. Повторення процесу: Ці кроки повторюються для кожного пакету тренувальних даних, доки мережа не пройде всі дані тренувального набору. Цей процес навчання повторюється декілька епох, поки модель не навчиться розпізнавати патерни та виконувати завдання з високою точністю.

3 РЕАЛІЗАЦІЯ НЕЙРОННИХ МЕРЕЖ

3.1 Розробка програмного забезпечення та використання бібліотечних рішень

Згорткові нейронні мережі можуть бути створені з використанням різних програмних мов, але Python є однією з найпопулярніших і має декілька переваг для розробки згорткових нейронних мереж:

Широкий вибір бібліотек: У Python є багато популярних бібліотек, таких як TensorFlow, Keras, PyTorch та Theano, які надають потужні інструменти для роботи з нейронними мережами. Ці бібліотеки мають готові реалізації згорткових шарів, функцій активації та інших компонентів, що спрощує розробку та експериментування з моделями.

Легкість використання: Python має простий і зрозумілий синтаксис, що полегшує розробку і розуміння коду. Велика спільнота розробників також означає, що ви можете знайти багато прикладів, документації та підтримки для ваших проєктів.

Інтеграція з іншими інструментами: Python широко використовується в області наукових обчислень і аналізу даних. Він має розширення і бібліотеки для роботи з різними типами даних, включаючи зображення, що полегшує інтеграцію згорткових нейронних мереж з іншими інструментами для попередньої обробки даних, візуалізації та аналізу результатів.

Висока продуктивність: У Python є оптимізовані бібліотеки, такі як TensorFlow та PyTorch, які дозволяють прискорити виконання обчислень. Ці бібліотеки підтримують використання GPU для прискорення обчислень в згорткових нейронних мережах, що робить їх ефективними для обробки великих обсягів даних.

В цілому, використання Python для розробки згорткових нейронних мереж є розумним вибором. Python надає зручний інтерфейс, широкий вибір бібліотек, зрозумілий синтаксис та високу продуктивність, що сприяє швидкій розробці та ефективному впровадженню моделей.

3.2 Підготовка тестових даних

Для даного дослідження було використано набір даних під назвою

Alzheimer'sDataset (4 classofImages) з платформи Kaggle. Kaggle - це онлайн-сервіс, який сприяє співпраці між науковцями з області даних та ентузіастами машинного навчання. Ця платформа дозволяє користувачам знаходити, публікувати та спільно працювати над наборами даних, використовувати графічні процесори у вбудованих ноутбуках та змагатися з іншими учасниками у вирішенні завдань з науки про дані. Головна мета Kaggle - допомогти професіоналам і студентам досягти своїх цілей у вивченні науки про дані, надаючи потужні інструменти та ресурси. На сьогоднішній день на Kaggle зареєстровано понад 8 мільйонів користувачів.

Набір даних містить 6400 зображень і поділений на 4 класи:

- NonDemented - клас MPT-зображень мозку здорових людей;
- Very Mild Demented - дуже легке ураження мозку;
- MildDemented - легке ураження мозку;
- Moderate Demented - помірне ураження мозку.

Перевагою даного датасету є те, що зображення вже очищені від "зайвих" фрагментів, які не впливають на діагностування хвороби Альцгеймера, що дозволяє навчати модель більш ефективно. Також датасет вже розділений на навчальні та тестувальні дані в співвідношенні 80:20. З недоліків, варто відзначити, що розмірність для навчання згорткових нейронних мереж має бути однаковою для ширини та висоти. Розмір зображення в даному датасеті становить 176x208. Однак це можна легко виправити додавши декілька рядків коду до моделі.

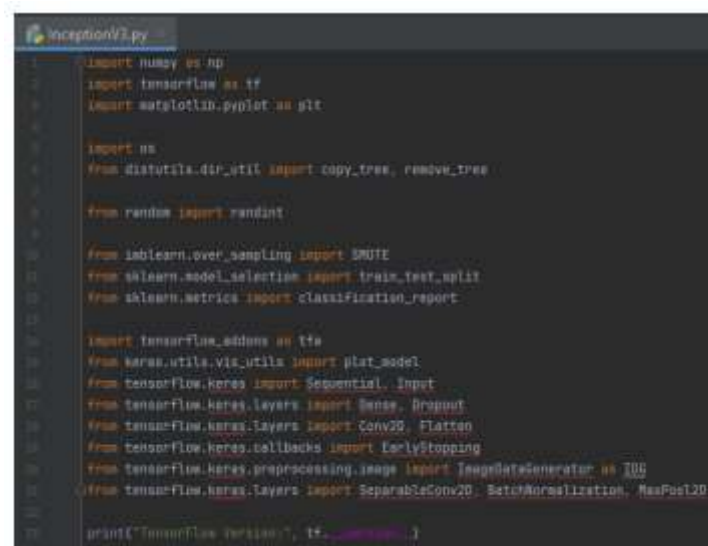
3.3 Проведення Експериментів.

У цьому дослідженні було проведено серію експериментів з метою визначення найбільш точної моделі серед InceptionV3, VGG19 та ResNet50. Далі будуть розглянуті переваги і недоліки кожної з них.

Перша модель, що була розглянута - InceptionV3. Це глибока згорткова нейронна мережа, створена командою Google Research для розпізнавання об'єктів на зображеннях. Її основна ідея полягає в використанні модулів Inception, які дозволяють мережі ефективно виявляти ознаки різного рівня деталізації, використовуючи фільтри різних розмірів паралельно і об'єднуючи їх в один вихід. Це сприяє покращенню

результатів у сфері комп'ютерного зору. Крім того, InceptionV3 використовує модуль зменшення розмірності перед складними блоками Inception, що знижує обчислювальні витрати і сприяє збільшенню глибини мережі.

Щодо написання коду, спочатку ми імпортуємо необхідні бібліотеки для виконання операцій з даними, навчання моделі, візуалізації та оцінки результатів.



```

1 import numpy as np
2 import tensorflow as tf
3 import matplotlib.pyplot as plt
4
5 import os
6 from distutils.dir_util import copy_tree, remove_tree
7
8 from random import randint
9
10 from imblearn.over_sampling import SMOTE
11 from sklearn.model_selection import train_test_split
12 from sklearn.metrics import classification_report
13
14 import tensorflow_addons as tfa
15 from keras.utils.vis_utils import plot_model
16 from tensorflow.keras import Sequential, Input
17 from tensorflow.keras.layers import Dense, Dropout
18 from tensorflow.keras.layers import Conv2D, Flatten
19 from tensorflow.keras.callbacks import EarlyStopping
20 from tensorflow.keras.preprocessing.image import ImageDataGenerator as IDS
21 from tensorflow.keras.layers import SeparableConv2D, BatchNormalization, MaxPool2D
22
23 print("TensorFlow version:", tf.__version__)
  
```

Рисунок 3.1 – Імпортування необхідних бібліотек

У цьому коді ми імпортуємо різні бібліотеки та модулі для виконання різноманітних операцій у машинному навчанні. Наприклад, NumPy використовується для роботи з масивами та математичними операціями, TensorFlow для побудови та навчання моделей, а Matplotlib для візуалізації графіків та зображень. Модуль os потрібний для роботи з операційною системою, включаючи роботу з файловою системою. distutils.dir_util містить функції для копіювання та видалення каталогів.

Далі ми імпортуємо різні функції та метрики з бібліотек imbalanced-learn (imblearn) та scikit-learn. Наприклад, SMOTE є алгоритмом для вирішення проблеми незбалансованості класів у наборі даних, а train_test_split використовується для розділення набору даних на тренувальну та тестову вибірки. MCC та BAS - це метрики для оцінки моделей, а classification_report та confusion_matrix використовуються для аналізу результатів класифікації.

Останній блок імпорту складається з різних класів та модулів з TensorFlow та Keras, що використовуються для побудови та навчання моделей глибокого навчання.

Вони містять такі компоненти, як Sequential, Input, Dense, Dropout, Conv2D, Flatten, EarlyStopping, InceptionV3, ImageDataGenerator та інші. Після імпортування ми виводимо на екран версію TensorFlow, результат на рисунку 3.2.



Рисунок 3.2 – Вивід на екран версії TensorFlow

Далі ми готуємо вхідні дані для нашої моделі перед тренуванням. Це включає визначення шляхів до необхідних папок у файловій системі, таких як папки базового каталогу, кореневої директорії, тестової та тренувальної папок. Ми також перевіряємо наявність робочої директорії: якщо вона вже існує, вона видаляється, а потім створюється нова робоча директорія. Файли з тренувальної та тестової папок копіюються в цю нову робочу директорію. Це дозволяє нам зібрати всі дані в одному місці для подальшої обробки.

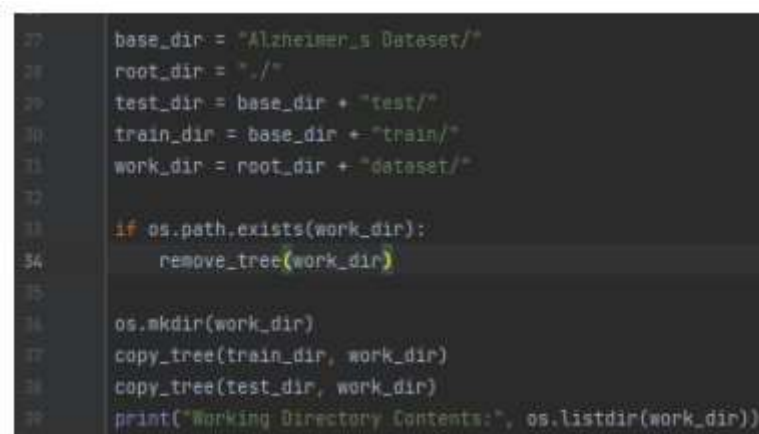


Рисунок 3.3 – Створення структури даних

Після завершення виконання коду виводиться список файлів та папок, що знаходяться в робочій директорії. Це допомагає переконатися, що структура даних була побудована правильно і всі файли та папки на місці, як очікувалося.



3.4 – Робоча директорія

Нам необхідно визначити кількість класів для класифікації та встановити розмір вхідних зображень, який, як зазначалося раніше, повинен бути квадратним з розміром $n \times n$.

```

41  WORK_DIR = './dataset/'
42
43  CLASSES = ['NonDemented',
44             'VeryMildDemented',
45             'MildDemented',
46             'ModerateDemented']
47
48  IMG_SIZE = 176
49  IMAGE_SIZE = [176, 176]
50  DIM = (IMG_SIZE, IMG_SIZE)

```

Рисунок 3.5 – Задання класів та визначення розмірів зображення

Ми проводимо аугментацію зображень, щоб отримати більшу різноманітність даних для навчання моделі. Параметри аугментації, такі як збільшення масштабу, діапазон яскравості, горизонтальне відображення та інші, визначаються змінними, такими як «ZOOM», «BRIGHT_RANGE», «HORZ_FLIP», «FILL_MODE» та «DATA_FORMAT». Ми створюємо екземпляр класу «ImageDataGenerator» з бібліотеки TensorFlow під назвою «work_dr», який використовується для аугментації зображень. Цей об'єкт налаштовується з використанням заданих параметрів, таких як масштабування зображень до діапазону від 0 до 1, зміна яскравості, збільшення масштабу тощо. «train_data_gen» є генератором даних, який створюватиме пакети зображень для навчання моделі. Ми вказуємо директорію «WORK_DIR», де знаходяться дані, «target_size» – розмір зображень, «batch_size» – розмір пакету зображень, і параметр «shuffle=False», щоб зберегти порядок зображень таким, як у директорії.

```

54 ZOOM = [.99, 1.01]
55 BRIGHT_RANGE = [0.8, 1.2]
56 HORZ_FLIP = True
57 FILL_MODE = "constant"
58 DATA_FORMAT = "channels_last"
59
60 work_dr = IDG(rescale=1. / 255, brightness_range=BRIGHT_RANGE, zoom_range=ZOOM, data_format=DATA_FORMAT,
61             fill_mode=FILL_MODE, horizontal_flip=HORZ_FLIP)
62
63 train_data_gen = work_dr.flow_from_directory(directory=WORK_DIR, target_size=DIM, batch_size=6500, shuffle=False)

```

Рисунок 3.6 – Аугментація зображень

Після завантаження та форматування даних, ми виводимо зображення на екран, щоб краще зрозуміти, які саме дані використовуються як вхідні для моделі.




Рисунок 3.7 – Вивід вхідних даних

```

100 #Retrieving the data from the ImageDataGenerator iterator
101 train_data, train_labels = train_data_gen.next()
102
103 #Getting to know the dimensions of our datasets
104 print(train_data.shape, train_labels.shape)
105
106 #Performing over-sampling of the data, since the classes are imbalanced
107 sm = SMOTE(random_state=42)
108 train_data, train_labels = sm.fit_resample(train_data.reshape(-1, IMG_SIZE * IMG_SIZE * 3), train_labels)
109 train_data = train_data.reshape(-1, IMG_SIZE, IMG_SIZE, 3)
110
111 print(train_data.shape, train_labels.shape)
112
113 |
114 #Splitting the data into train, test, and validation sets
115
116 train_data, test_data, train_labels, test_labels = train_test_split(train_data, train_labels, test_size=0.2, random_state=42)
117 train_data, val_data, train_labels, val_labels = train_test_split(train_data, train_labels, test_size=0.2, random_state=42)

```

Рисунок 3.8 – Перебалансування даних

У цьому відрізку (рис. 3.8) ми виконуємо наступні кроки:

1. Застосовуємо аугментацію зображень для отримання більшого розмаїття прикладів даних. Для цього ми використовуємо ImageDataGenerator для створення даних з генератора train_data_gen.
2. Виводимо розмірність набору даних (train_data) та міток (train_labels), щоб переконатися, що дані коректно отримані.
3. Виконуємо oversampling (перебалансування) даних, оскільки класи набору даних не є збалансованими. Для цього використовуємо метод SMOTE для збільшення кількості зразків, створюючи штучні приклади меншістю класів. Ми конвертуємо дані (train_data) та мітки (train_labels) у формат, який може бути використаний SMOTE, а потім повертаємо їх у початковий формат.
4. Розділяємо дані на тренувальний набір (train_data, train_labels), тестовий набір (test_data, test_labels) та валідаційний набір (val_data, val_labels). Це виконується за допомогою функції train_test_split. Розмір тестового та валідаційного набору становить 20% від загального набору даних, і ми використовуємо випадковий стан (random_state=42) для забезпечення повторюваності розділення даних.

Результати виводу на екран, рисунок 3.9:

```

Found 6400 images belonging to 4 classes.
(6400, 176, 176, 3) (6400, 4)
(12800, 176, 176, 3) (12800, 4)

```

Рисунок 3.9 – Балансування даних

Перейдемо до створення архітектури моделі, рисунок 3.10, 3.11:

```

121 def conv_block(filters, act='relu'):
122     """Defining a Convolutional NN block for a Sequential CNN model. """
123
124     block = Sequential()
125     block.add(Conv2D(filters, 3, activation=act, padding='same'))
126     block.add(Conv2D(filters, 3, activation=act, padding='same'))
127     block.add(BatchNormalization())
128     block.add(MaxPool2D())
129
130     return block
131
132
133 def dense_block(units, dropout_rate, act='relu'):
134     """Defining a Dense NN block for a Sequential CNN model. """
135
136     block = Sequential()
137     block.add(Dense(units, activation=act))
138     block.add(BatchNormalization())
139     block.add(Dropout(dropout_rate))
140
141     return block
142

```

Рисунок 3.10 – Створення архітектури моделі (перша частина)

```


def construct_model(act='relu'):
    """Constructing a Sequential CNN architecture for performing the classification task. """

    model = Sequential([
        Input(shape=(*IMAGE_SIZE, 3)),
        Conv2D(16, 3, activation=act, padding='same'),
        Conv2D(16, 3, activation=act, padding='same'),
        MaxPool2D(),
        conv_block(32),
        conv_block(64),
        conv_block(128),
        Dropout(0.2),
        conv_block(256),
        Dropout(0.2),
        Flatten(),
        dense_block(512, 0.7),
        dense_block(128, 0.5),
        dense_block(64, 0.3),
        Dense(4, activation='softmax')
    ], name="cnn_model")

    return model

```

Рисунок 3.11 – Створення архітектури моделі (друга частина)



Model: "cnn_model"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 176, 176, 16)	448
conv2d_1 (Conv2D)	(None, 176, 176, 16)	2320
max_pooling2d (MaxPooling2D)	(None, 88, 88, 16)	0
sequential (Sequential)	(None, 64, 64, 32)	14016
sequential_1 (Sequential)	(None, 22, 22, 64)	55680
sequential_2 (Sequential)	(None, 11, 11, 128)	221952
dropout (Dropout)	(None, 11, 11, 128)	0
sequential_3 (Sequential)	(None, 5, 5, 256)	886272
dropout_1 (Dropout)	(None, 5, 5, 256)	0
flatten (Flatten)	(None, 6400)	0
sequential_4 (Sequential)	(None, 512)	3279360
sequential_5 (Sequential)	(None, 128)	66176
sequential_6 (Sequential)	(None, 64)	8512
dense_1 (Dense)	(None, 4)	260

Total params: 4,534,996
 Trainable params: 4,532,428
 Non-trainable params: 2,568

Рисунок 3.12 – Вивід шарів створенної архітектури

У цьому відрізку (рис. 3.13) ми встановлюємо деякі інші параметри для нашої згорткової нейронної мережі. Спочатку ми викликаємо функцію `construct_model()`, яка будує архітектуру нашої ЗНМ. Потім ми визначаємо список метрик, які хочемо використовувати для оцінки продуктивності моделі. У цьому випадку, ми використовуємо метрики категоріальної точності, площі під кривою AUC і F1-оцінки для 4 класів. Після цього ми компілюємо модель, використовуючи оптимізатор "adam", функцію втрати "CategoricalCrossentropy" і визначені раніше метрики. Нарешті, ми виводимо зведену інформацію про модель за допомогою методу `summary()`, який показує детальну інформацію про шари та параметри моделі (рис. 3.14).


```

183     model = construct_model()
184
185     METRICS = [tf.keras.metrics.CategoricalAccuracy(name='acc'),
186                tf.keras.metrics.AUC(name='auc'),
187                tf.keras.metrics.F1Score(num_classes=4)]
188
189     CALLBACKS = [my_callback]
190
191     model.compile(optimizer='adam',
192                  loss=tf.keras.losses.CategoricalCrossentropy(),
193                  metrics=METRICS)
194
195     model.summary()

```

Рисунок 3.13 – Встановлення додаткових параметрів для моделі

```

=====
Total params: 4,534,996
Trainable params: 4,532,628
Non-trainable params: 2,368
=====

```

Рисунок 3.14 – Інформація про параметри моделі


Процес навчання моделі передбачає проведення 20 епох (і при потребі можна продовжити навчання), що зазвичай є досить для оптимального навчання. Довше навчання може призвести до перенавчання моделі на тренувальних даних, коли модель стає надто специфічною для цих даних і втрачає здатність адекватно узагальнювати на нові дані. Це означає, що модель може "запам'ятовувати" тренувальні дані, що може призвести до погіршення її ефективності на нових даних. Процес навчання зображений на рисунку 3.15.

```

Epoch 16/20
256/256 [=====] - 256s 991ms/step - loss: 0.2809 - acc: 0.8888 - auc: 0.9819 - f1_score: 0.8888 - val_loss: 0.4673 - val_acc: 0.8847 - val_auc: 0.9804 - val_f1_score: 0.7903
Epoch 17/20
256/256 [=====] - 256s 978ms/step - loss: 0.2681 - acc: 0.8966 - auc: 0.9866 - f1_score: 0.8966 - val_loss: 0.2989 - val_acc: 0.8833 - val_auc: 0.9809 - val_f1_score: 0.8822
Epoch 18/20
256/256 [=====] - 256s 983ms/step - loss: 0.2087 - acc: 0.9235 - auc: 0.9914 - f1_score: 0.9235 - val_loss: 1.0638 - val_acc: 0.5669 - val_auc: 0.8258 - val_f1_score: 0.5659
Epoch 19/20
256/256 [=====] - 256s 994ms/step - loss: 0.2039 - acc: 0.9231 - auc: 0.9917 - f1_score: 0.9230 - val_loss: 0.3681 - val_acc: 0.9009 - val_auc: 0.9873 - val_f1_score: 0.8990
Epoch 20/20
256/256 [=====] - 256s 1s/step - loss: 0.1999 - acc: 0.9271 - auc: 0.9919 - f1_score: 0.9272 - val_loss: 0.3273 - val_acc: 0.8813 - val_auc: 0.9814 - val_f1_score: 0.8776
88/88 [=====] - 1s 201ms/step - loss: 0.3378 - acc: 0.8789 - auc: 0.9802 - f1_score: 0.8785
Testing Accuracy: 87.89%
88/88 [=====] - 1s 199ms/step

```

Рисунок 3.15 – Процес навчання моделі



	precision	recall	f1-score	support
NonDemented	0.95	0.97	0.96	639
VeryMildDemented	0.95	1.00	0.97	635
MildDemented	0.97	0.63	0.76	662
ModerateDemented	0.72	0.93	0.81	624

Рисунок 3.16 – Результат навчання

Відповідно до зображення 3.16:

Втрати (Loss): Це числове значення, що вказує на те, наскільки добре модель прогнозує правильні класи для вхідних даних. Менше значення втрат означає кращу ефективність моделі.

Точність (Accuracy): Це відношення кількості правильно класифікованих прикладів до загальної кількості прикладів у наборі даних. Висока точність, близька до 1, свідчить про високу ефективність моделі.

AUC (Area Under the ROC Curve): Це міра якості моделі класифікації, що вказує на її здатність розрізняти між двома класами. Вона вимірюється як площа під кривою ROC і знаходиться між 0 і 1. Високе значення AUC показує високу здатність моделі розрізняти класи.

F1-показник (F1 Score): Це міра точності моделі, яка об'єднує інформацію про точність і повноту моделі в одне значення. Він обчислюється як гармонічне середнє точності і повноти і також знаходиться між 0 і 1. Високе значення F1-показника вказує на високу точність і повноту моделі.

На зображенні 3.18 показано результати прогнозування для конкретного зображення, включаючи клас, до якого воно належить, а також впевненість у цьому прогнозі.

```

def load_and_preprocess_image(image_path):
    image = tf.keras.preprocessing.image.load_img(image_path, target_size=IMAGE_SIZE)
    image = tf.keras.preprocessing.image.img_to_array(image)
    image = image / 255.0 # Normalize image
    image = np.expand_dims(image, axis=0) # Add batch dimension
    return image

# Function to predict class and confidence
def predict_image(image_path):
    image = load_and_preprocess_image(image_path)
    predictions = model.predict(image)
    predicted_class_index = np.argmax(predictions)
    predicted_class = CLASSES[predicted_class_index]
    confidence = np.max(predictions) * 100
    return predicted_class, confidence

# Path to the image you want to test
image_path = 'data/rust/ModerateDemented/28_2.jpg'

# Display the predicted class and confidence
predicted_class, confidence = predict_image(image_path)
print("Predicted Class:", predicted_class)
print("Confidence:", confidence)

```

Рисунок 3.17 – Функція прогнозування

```

1/1 [=====] - 0s 194ms/step
Predicted Class: ModerateDemented
Confidence: 99.99920129776001

```

Рисунок 3.18 – Прогнозування

Друга модель, VGG19 (Visual Geometry Group 19), розроблена командою дослідників з Університету Оксфорду, є однією з популярних архітектур глибоких нейронних мереж. Вона є поліпшеною версією VGG16 і використовує невеликі фільтри розміром 3x3 для згорткових та пулінгових шарів. Цей підхід дозволяє підвищити глибину мережі та знизити кількість параметрів, покращуючи якість розпізнавання зображень. Основні характеристики VGG19 включають 19 шарів, включаючи 16 згорткових та 3 повнозв'язних шари. Вона також використовує функцію активації ReLU і softmax для класифікації. Відома своєю глибиною, модель має понад 143 мільйони параметрів, що призводить до великого обчислювального навантаження.

Третя модель, ResNet50 (Residual Network 50), базується на архітектурі ResNet і має 50 шарів. Це один з ключових проривів у галузі комп'ютерного зору, оскільки вона допомогла вирішити проблему зникаючих градієнтів та навчання глибоких нейронних мереж з багатьма шарами.

Основна ідея ResNet полягає у використанні "блоків з нейронними

залишками" для створення моделі. Звичайні нейронні мережі можуть стикатися з проблемами зі зникаючими градієнтами під час навчання, оскільки дані проходять через кожен шар. У ResNet це вирішується за допомогою "шляхів перехідних з'єднань", які дозволяють обійти деякі шари та додають нейронні залишки напряму до наступних шарів. Це допомагає полегшити поширення градієнтів через мережу, що поліпшує процес навчання. ResNet50 складається з 50 шарів, включаючи згорткові, шари пакетної нормалізації, активаційні функції і повнозв'язні шари. Код для InceptionV3, VGG19 і ResNet50 можна знайти в додатках А, Б і В відповідно.

3.4 Аналіз отриманих результатів.

У попередньому розділі були зазначені три моделі: InceptionV3, VGG19 та ResNet50. Після навчання кожної з цих моделей було створено таблиці з порівняльними метриками якості для тестових даних. Давайте розглянемо результати для першої моделі, InceptionV3.

Таблиця 3.1 – Метрики навчання InceptionV3

Loss	Accuracy	Auc	F1-score
0.34	0.88	0.98	0.88

Результати для другої – VGG19 (табл. 3.2) та третьої моделей – ResNet50 (табл. 3.3):

Таблиця 3.2 – Метрики навчання VGG19

Loss	Accuracy	Auc	F1-score
0.68	0.7	0.92	0.62

Таблиця 3.3 – Метрики навчання ResNet50

Loss	Accuracy	Auc	F1-score
0.71	0.56	0.86	0.44

Отже, як бачимо, найбільшу точність показала модель InceptionV3, на відміну від інших двох запропонованих моделей.

4 ОХОРОНА ПРАЦІ

Дослідження методу обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера відбувалося в приміщенні, яке обладнане робочими місцями з ПК. На дослідника могли мати вплив такі небезпечні та шкідливі виробничі фактори:

1. Фізичні: підвищена запиленість та загазованість повітря робочої зони; підвищена чи понижена температура повітря робочої зони; підвищений рівень шуму на робочому місці; підвищений рівень електромагнітного випромінювання; підвищена чи понижена іонізація повітря; недостатня освітленість робочої зони; відсутність чи нестача природного освітлення.

2. Психофізіологічні: статичне перевантаження; розумове перевантаження; емоційні перевантаження.

Відповідно до наведених факторів здійснюємо планування щодо безпечного виконання роботи.

4.1. Технічні рішення щодо безпечного виконання роботи

Конструкція робочого місця та взаємне розташування усіх її елементів має відповідати антропометричним, фізичним і неординарним психологічним вимогам.

Більшість сучасних комп'ютерних стільців оснащені коліщатами і шарнірами, що дозволяє вільно переміщатися по всій площі службового приміщення. Крім того, такі стільці обладнані спинками, що дозволяє запобігти надмірному навантаженню на шию і спину. Для вибору стільця слід звернути увагу на наступні характеристики: наявність регульованого по висоті сидіння; наявність спинки, регульованої як по висоті, так і в поперечному напрямі; наявність достатньої глибини сидіння; належна стійкість; наявність коліщаток, відповідних покриттю підлоги у приміщенні.

При регулюванні стільця необхідно враховувати як розміри тіла, так і висоту робочої поверхні столу, якщо вона не регулюється. Висоту сидіння треба відрегулювати так, щоб можна було зручно розташуватися на ньому; при цьому ступні ніг повинні опиратися на підлогу, а зазор між передньою частиною стільця і

ногами дослідника повинен складати 5 сантиметрів. Після цього слід відрегулювати спинку як у вертикальному, так і в поперечному напрямках, щоб не напружувався поперек.

Щодня перед початком роботи працівник повинен:

- оглянути своє робоче місце; про виявлення ознак пошкодження обладнання інформувати свого безпосереднього керівника;
- відрегулювати освітленість на робочому місці, переконатися в відсутності відблисків на екрані комп'ютера, відсутності зустрічного світла;
- перевірити правильність підключення обладнання ПК до електромережі;
- очистити екран комп'ютера від пилу та інших забруднень;
- перевірити правильність організації робочого місця й за необхідності провести відповідні коригування.

Працівник під час роботи зобов'язаний:

- виконувати тільки ту роботу, яку йому було доручено;
- підтримувати порядок і чистоту на робочому місці;
- тримати відкритими всі вентиляційні отвори обладнання;
- коректно закрити всі активні завдання у разі припинення роботи з комп'ютером;
- негайно відключити комп'ютером від електричної мережі у разі виникнення аварійної ситуації.

У ході виконання робіт працівник повинен:

- витримувати відстань від очей до екрана комп'ютером в межах 60 - 70см;
- дотримуватися внутрішньозмінного режиму праці та відпочинку, регламентованих перерв у роботі;

Під час регламентованих перерв рекомендується виконувати комплекси вправ для очей, рук, хребта, поліпшення мозкового кровообігу тощо. Про виявлення несправності обладнання або інших факторів, які створюють загрозу для життя або здоров'я працівників, необхідно негайно інформувати свого безпосереднього керівника.

Не допускається:

- виконання ремонту та налагодження комп'ютерної техніки безпосередньо на робочому місці оператора;
- зберігання біля комп'ютера паперу, дискет, інших носіїв інформації, запасних блоків, деталей тощо, якщо вони не використовуються для поточної роботи;
- відключення захисних пристроїв, самочинні зміни в конструкції комп'ютера;
- використання комп'ютерів, на екранах яких під час роботи з'являються нехарактерні сигнали, нестабільне зображення на екрані тощо;
- доторкання до задньої панелі системного блоку при включеному живленні;
- вимикання живлення під час виконання активного завдання;
- попадання вологи на поверхню системного блоку, монітора, клавіатури, дисководів, принтерів та інших пристроїв;
- приймання напоїв та їжі на робочому місці.

Після закінчення роботи з використанням необхідно дотримуватися такої послідовності вимикання обладнання:

- закрити всі активні завдання;
- використавши опцію «Завершення роботи» у меню «Пуск», вимкнути живлення системного блоку;
- вимкнути живлення всіх комп'ютерів;
- вимкнути блок аварійного живлення (за наявності);
- відключити комп'ютер від електромережі, при цьому забороняється тягнути штепсельну вилку за дріт.

Приміщення, де здійснювалося дослідження методу обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера використовується чотири провідна трифазна електромережа з заземленим нульовим проводом. Величина напруги цієї мережі становить 380 х 220В (фазна напруга (фаза – «0») – 220В, а міжфазна лінійна (фаза – фаза) – 380В).

Категорія умов з небезпеки електротравматизму – без підвищеної небезпеки, оскільки чинники підвищеної небезпеки (підвищена температура повітря (більша за 35°C), вологість (більша 75%), струмопровідна підлога, струмопровідний пил,

можливість одночасного дотику обслуговуючого персоналу до металевого корпусу споживача електроенергії та металоконструкцій, що мають зв'язок із землею) та особливої небезпеки (вологість повітря в приміщеннях близька до насичення, конденсація вологи на поверхні устаткування та будівельних конструкціях (100%); хімічно активне середовище, що призводить до руйнування ізоляції, чи біологічне середовище, що у вигляді плісняви утворюється на обладнанні та струмовідних елементах) відсутні.

4.2. Технічні рішення з гігієни праці та виробничої санітарії

4.2.1. Мікроклімат

Життєдіяльність людини завжди протікає у певних метеорологічних умовах, що визначаються поєднанням температури повітря, швидкості його руху і відносної вологості, барометричним тиском та інтенсивністю теплового випромінювання. Ці показники в сукупності (за винятком барометричного тиску) характеризують метеорологічні умови середовища (мікроклімат) виробничого приміщення. Якщо робота виконується на відкритих майданчиках, то метеорологічні умови визначаються кліматичним поясом і сезоном року. Проте і в цьому випадку в робочій зоні створюється певний мікроклімат.

Параметри мікроклімату закритих приміщень нормують санітарні норми ДСН 3.3.6.042-99 [29]. Робота з дослідження методу обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера за енерговитратами відноситься до категорії І а (енерговитрати до 139Дж/с) [30]. Допустимі параметри мікроклімату для цієї категорії наведені в табл.4.2.1.

Таблиця 4.2.1 – Параметри мікроклімату

Період року	Допустимі		
	t, °C	W, %	V, м/с
Теплий	22-28	55	0,1-0,2
Холодний	21-25	75	0,1

Для забезпечення вказаних параметрів мікроклімату в приміщенні передбачено використання централізованої парової системи опалення, системи механічної вентиляції, систематичного провітрювання та вологого прибирання (раз за зміну).

4.2.2. Склад повітря робочої зони

Повітря робочої зони залежно від хімічного складу, фізичних властивостей, наявності забруднюючих чинників може бути сприятливим, несприятливим або навіть небезпечним. Сприятливим повітряне середовище в робочій зоні буває тоді, коли воно має відповідну чистоту, нормальні хімічні показники та нормальний мікроклімат.

В приміщенні, де здійснюється дослідження методу обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера у повітрі можуть бути наявні підвищені концентрації пилу та озону. Джерелами цих речовин є офісна техніка. Пил потрапляє у приміщення ззовні. ГДК шкідливих речовин, які знаходяться в досліджуваному приміщенні, наведені в таблиці 4.2.2.

Таблиця 4.2.2 – ГДК шкідливих речовин у повітрі

Назва речовини	ГДК, мг/м ³	Середньо добова	Клас небезпечності
	Максимально разова		
Пил нетоксичний	0,5	0,15	4
Озон	0,16	0,03	1
Вуглекислий газ	3	1	4

Для забезпечення у виробничих приміщеннях оптимальних параметрів мікроклімату та належної чистоти повітря (граничнодопустимих концентрацій шкідливих речовин) використовують вентилювання приміщень, яке здійснюють за допомогою сукупності пристроїв для транспортування, подання та видалення повітря.

4.2.3. Виробниче освітлення

Недостатність освітлення призводить до напруги зору, послаблює увагу, призводить до подальшої передчасної стомлюваності. Надмірно яскраве освітлення викликає осліплення, роздратування і різь в очах. Неправильний напрям світла на робочому місці може створювати різкі тіні, відблиски, дезорієнтувати працюючого. Всі ці причини можуть призвести до професійних захворювань, тому надзвичайно важливе значення має забезпечення оптимальної освітленості на робочому місці.

Згідно ДБН В.2.5-28-2018 [31] в приміщеннях, де здійснюється дослідження методу обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера на ПК необхідно застосувати систему комбінованого освітлення.

Норми освітленості при штучному освітленні та КПО (для III пояса світлового клімату) при природному та сумісному освітленні зазначені у таблиці 4.2.4:

Таблиця 4.2.4 - Норми освітленості в приміщенні

Характеристика зорової роботи	Найменший розмір об'єкта розрізнення	Розряд зорової роботи	Підрозряд зорової роботи	Контраст об'єкта розрізнення з фоном	Характеристика фона	Освітленість, Лк		КПО, e_n , %			
						Штучне освітлення		Природне освітлення		Сумісне освітлення	
						Комбіноване	Загальне	Верхнє або верхнє	Бокове	Верхнє або верхнє	Бокове
Дуже високої точності	Від 0,15 до 0,3	II	г	великий	світлий	1000	300	7	2,5	4,2	1,5

Для нормалізації освітленості в приміщенні слід передбачити обмеження прямої блискоті від джерел природного та штучного освітлення. При цьому яскравість світлих поверхонь (вікна, джерела штучного освітлення), що розташовані в полі зору повинна бути не більше ніж 200 кд/м^2 . Необхідно обмежувати відбиту блискоті на робочих поверхнях відносно джерел природного і штучного освітлення.

При цьому яскравість відблисків на екрані ВДТ має не перевищувати 40 кд/м², а яскравість стелі в разі застосування системи відбитого освітлення – 200 кд/м².

4.2.4. Виробничий шум

Шум - безладне сполучення різних по силі і частоті звуків; здатний здійснювати несприятливу дію на організм працівника. Джерелом шуму є будь-який процес, що викликає місцеву зміну тиску або механічні коливання в жорстких, водянистих або газоподібних середовищах. Джерелами шуму можуть бути двигуни, насоси, компресори, турбіни, пневматичні та електричні інструменти, молоти, долота, верстати, центрифуги, бункери та інші установки.

Реакція людини на шум різна. Деякі люди досить терплячі до шуму, у інших він викликає роздратування. Психологічна оцінка шуму в основному базується на понятті сприйняття, причому велике значення має внутрішнє налаштування до джерела шуму. Воно визначає, чи буде шум сприйматися як перешкода робочому процесу. Часто шум, який здійснюється самим працівником, не турбує його, в той час як невеликий шум, викликаний сусідами або іншим джерелом, має значний подразнюючий ефект.

Допустимі рівні звукового тиску у октавних смугах частот, еквівалентні рівні звуку на місцях праці встановлені санітарними нормами виробничого шуму, ультразвуку та інфразвуку ДСН 3.3.6.037-99 [32], витяг з яких подано в табл. 4.2.5

Таблиця 4.2.5 – Допустимі еквівалентні рівні шуму на робочих місцях

Вид професійної діяльності, місце праці	Еквівалентні рівні шуму, дБ
Творча діяльність, керівна робота з підвищеними вимогами, наукова діяльність, конструювання та проектування, програмування, викладання та навчання, лікарська діяльність; місця праці у приміщеннях – дирекції, проектно-конструкторських бюро, програмістів обчислювальних машин, у лабораторіях для теоретичних робіт та опрацювання даних, прийому хворих у медпунктах	50
Висококваліфікована робота, що вимагає зосередження, адміністративно-керівна діяльність, вимірювальні та аналітичні роботи у лабораторії; місця праці в приміщеннях цехового керівного апарату, контор, лабораторій	60

4.2.5. Виробничі випромінювання

Електромагнітні поля негативно впливають на організм людини, яка безпосередньо працює з джерелом випромінювання, а також на населення, яке мешкає поблизу джерел випромінювання.

В будь-якій точці ПК промислової частоти енергія магнітної складової поля, яка поглинається тілом людини, майже в 50 разів менша від енергії електричної складової цього поля, що поглинається тілом. Це дає змогу зробити висновок, що в діапазоні промислових частот дією магнітної складової поля на біологічний об'єкт можна знехтувати, а негативний вплив на організм обумовлений електричною складовою поля.

Вимоги до рівня неіонізувальних електромагнітних випромінювань, електростатичних та магнітних полів наведені у табл. 4.2.6.

Таблиця 4.2.6 – Допустимі параметри електромагнітних неіонізувальних випромінювань і електростатичного поля

Види поля	Допустимі параметри поля		Допустима поверхнева щільність потоку енергії (інтенсивність потоку енергії), Вт/кв.м
Напруженість електромагнітного поля	за електричною складовою (E), В/м	за магнітною складовою (H), А/м	
60 кГц до 3 мГц	50	5	
3 кГц до 30 мГц	20	-	
30 кГц до 50 мГц	10	0,3	
30 кГц до 300 мГц	5	-	
Електромагнітне поле оптичного діапазону в ультрафіолетовій частині спектру			
УФ-С (220 - 280 нм)			0,001
УФ-В (280 - 320 нм)			0,01
УФ-А (320 - 400 нм)			10,0
0,76 - 10,0 мкм			35,0-70,0
Напруженість електричного поля ВДТ			20 кВ/м

Для зниження дії цих видів випромінювання рекомендується застосовувати монітори із зниженим рівнем випромінювання, встановлювати захисні екрани, а також дотримуватися регламентованих режимів праці та відпочинку.

4.3. Пожежна безпека

Будівлі та приміщення, в яких експлуатуються ПК та виконуються їх обслуговування, налагодження і ремонт повинні відповідати вимогам з пожежної безпеки. Неприпустимим є розташування приміщень категорій А і Б, а також виробництв з мокрими технологічними процесами поряд з приміщеннями, де розташовуються ПК, виконується їх обслуговування, налагодження і ремонт, а також над такими приміщеннями або під ними.

В приміщенні, де здійснювалося дослідження методу обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера використовуються тільки негорючі речовини та матеріали у холодному стані, тому за ступенем вибухопожежної та пожежної небезпеки приміщення відноситься до категорії «Д». Пожежну небезпеку несуть у собі лише кабельні електропроводки до обладнання, що є припустимим для даної категорії приміщень.

За вогнестійкістю приміщення відноситься до другої категорії [34]. Робоча зона працівника відноситься до класу вибухонебезпечності В-Па та пожежонебезпечності П-Па, оскільки вибухонебезпечна концентрація пилу і волокон може утворюватися лише внаслідок аварії або несправності.

4.3.1. Технічні рішення системи запобігання пожежі

Можливі причини виникнення пожежі у приміщенні, де здійснювалося дослідження підвищення ефективності систем синхронізації в цифрових засобах зв'язку такі:

- несправна електропроводка (іскріння, перегрів провідників, пересихання електроізоляційних матеріалів);
- використання електропобутових пристроїв (електрочайники, обігрівачі); попадання вологи на працююче електрообладнання;
- залишення без нагляду увімкнутих комп'ютерів, обчислювальної техніки

та інших електроприладів.

Для запобігання виникнення пожежі доцільні такі заходи:

- призначення осіб, що відповідальні за пожежну безпеку приміщення;
- щорічне проведення повторних протипожежних інструктажів та занять за програмою пожежно-технічного мінімуму з особами, що відповідальні за пожежну безпеку;
- утримання в справному стані засобів протипожежного захисту;
- своєчасне інформування про несправність пожежної техніки, систем протипожежного захисту, водопостачання тощо.

4.3.2. Технічні рішення системи протипожежного захисту

Переважна більшість пожеж починається із невеличкого вогнища. Тому його своєчасну ліквідацію розглядаємо як профілактичний захід щодо недопущення його розширення до масштабів пожежі. Ліквідувати вогнище можна, усунувши одну із трьох умов виникнення горіння. Видалити горючу речовину із вогнища не завжди можна, а припинити доступ кисню до неї або/і понизити її температуру можна завжди, якщо своєчасно використати первинні засоби гасіння пожеж: воду, пісок або вогнегасники.

У приміщені на випадок виникнення пожежі для обмеження її розповсюдження знаходиться переносний вуглекислотний вогнегасник типу ОУ-5, що відповідає нормам [37]. Підходи до засобів первинного пожежогасіння та відключення електросхем устаткування вільні.

У коридорі приміщення розташована схема евакуації людей при пожежі. Шляхи евакуації з відділу відповідають правилам пожежної безпеки. У будинку є два виходи, ширина коридору – 2-3 метри, ширина дверей – 0,8 м., двері відкриваються по ходу руху людей у випадку евакуації.

В цілому приміщення по категорії вибухо- і пожежонебезпечності та ступеню вогнестійкості відповідає нормам.

ВИСНОВКИ

У даній бакалаврській роботі проведено дослідження та аналіз проблеми виявлення хвороби Альцгеймера, яка є однією з основних проблем у медичній практиці сьогодення. Було детально розглянуто сутність хвороби, її етапи, причини та клінічні прояви. Особлива увага була приділена біомаркерам структурних змін у головному мозку, які можна виявити на зображеннях МРТ пацієнтів.

Проведений аналіз існуючих методів автоматизованого визначення хвороби Альцгеймера на МРТ-зображеннях підтвердив, що найкращим підходом є використання згорткових нейронних мереж. Ці мережі ефективно розпізнають об'єкти та обробляють зображення, що є ключовим аспектом при аналізі зображень МРТ головного мозку.

З метою розробки програмного забезпечення для автоматизованого виявлення хвороби Альцгеймера на МРТ-зображеннях було сформульовано завдання з розробки згорткової нейронної мережі для класифікації зображень. В якості даних для навчання був використаний набір даних Alzheimer's Dataset (4 class of Images) з платформи Kaggle, а також побудовано три популярні згорткові мережі: InceptionV3, VGG19 та ResNet50.

Після аналізу результатів метрик на тестових даних кожної моделі було встановлено, що InceptionV3 демонструє найкращі показники та найбільш підходить для розпізнавання хвороби Альцгеймера на МРТ-зображеннях.

Отже, розроблена згорткова нейронна мережа на основі моделі InceptionV3 може бути використана для раннього виявлення хвороби Альцгеймера за допомогою аналізу МРТ-зображень головного мозку пацієнтів. Результати дослідження мають потенціал покращити точність діагнозу та сприяти своєчасному початку лікування цієї нейродегенеративної хвороби.

ПЕРЕЛІК ЛІТЕРАТУРИ

1. Yadav S. S., Jadhav S. M. Deep convolutional neural network based medical image classification for disease diagnosis. Journal of Big Data. 2019. Vol. 6, no. 1. DOI: <https://doi.org/10.1186/s40537-019-0276-2>
2. Lakhani P., Sundaram B. Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural Networks. Radiology. 2017. Vol. 284, no. 2. P. 574–582. DOI: <https://doi.org/10.1148/radiol.2017162326>
3. Reproducible and interpretable deep learning for the diagnosis, prognosis and subtyping of Alzheimer’s disease from neuroimaging data – Wikipedia: веб-сайт. URL: https://en.wikipedia.org/wiki/Comparison_of_code_generation_tools (дата звернення: 03.05.2023).
4. Computer-Aided Diagnosis of Dementia based on structural MRI data. – Grand Challenge: веб-сайт. URL: <https://caddementia.grand-challenge.org/> (дата звернення: 05.05.2023).
5. Deep Learning with Convolutional Neural Network for Differentiation of Liver Masses at Dynamic Contrast-enhanced CT: A Preliminary Study / K. Yasaka et al. Radiology. 2018. Vol. 286, no. 3. P. 887–896.
6. Chris Albon, Machine learning with Python Cookbook/ Chris Albon – Mar 2018. 384 p.
7. Deep Convolutional Neural Networks for Automated Diagnosis of Alzheimer’s Disease and Mild Cognitive Impairment Using 3D Brain MRI – CodeSmith Researchgate: веб-сайт. URL: https://www.researchgate.net/figure/Deep-CNNarchitecture-used-for-the-proposed-Alzheimers-Disease-diagnosisframework_fig5_332212620(дата звернення: 06.05.2023).
8. Convolutional neural network – Wikipedia: веб-сайт. URL: https://en.wikipedia.org/wiki/Convolutional_neural_network#:~:text=A%20CNN%20architecture%20is%20formed,of%20layers%20are%20commonly%20used
9. Activation Functions in Neural Networks – Towards Data Science: веб-сайт. URL: <https://towardsdatascience.com/activation-functions-neural-networks1cbd9f8d91d6>

(дата звернення: 11.05.2023).

10. Нейронні мережі – шляхдо глибинного навчання – Codeguida: веб-сайт. URL: <https://codeguida.com/post/739> (дата звернення: 18.05.2023).

11. Татарин М. М., ЯкимовичГ. М., ПанкевичН. А. Хвороба Альцгеймера (Бібліографічний показчик): Івано-Франківськ 2021. 15 с.

12. Хвороба Альцгеймера: симптоми, лікування. Веб-сайт.URL: <https://medikom.ua/bolezn-alcgejmera-simptomy-lechenie/#Etiologiya>(дата звернення: 18.05.2023).

13. Dickson, W. Identification of normal and pathological aging in prospectively studied nondemented elderly humans/ Wan Dickson. – Feb 1992. 179 – 189 p.

14. The Radiology Assistant: Dementia - Role of MRI. The Radiology Assistant : Home. URL: <https://radiologyassistant.nl/neuroradiology/dementia/role-of-mri> (date of access: 14.05.2023)

15. Олещенко Л.М. Машинне навчання: навч. посіб. / Київ. нац. ун-т ім. Ігоря Сікорського. Київ: 2022. 92 с.

16. Метод опорних векторів –Wikipedia: веб-сайт. URL:https://upload.wikimedia.org/wikipedia/commons/thumb/7/72/SVM_margin.png/1024px-SVM_margin.png(дата звернення: 23.05.2023).

17. Згорткові нейронні мережі – YouTube: веб-сайт. URL:https://www.youtube.com/watch?v=Qkq0VLuw5Vg&list=PL_ug4sOLLpQiHmRGMki4ID6By9nPzAH0A&index=23 (дата звернення: 23.05.2023).

18. Тимченко А.О, Скачков В.О. Функція активації нейрона ReLu: Житомирський державний технологічний університет. Житомир: 2018. 1 с.

19. Навчання штучної нейронної мережі методом зворотного розповсюдження помилки – Studfile:веб-сайт. URL:<https://studfile.net/preview/5461803/> (дата звернення: 23.05.2023).

20. М.А. Новотарський, Б.Б. Нестеренко. Штучні нейронні мережі: Обчислення: Інститут математики НАН України. Київ: 2004. 207 с

21. Зінченко О. В., Звенігородський О. С., Кисіль Т. М. Згорткові нейронні мережі для вирішення задач комп'ютерного зору: Державний університет телекомунікацій. Київ: 2022. 73 с.

22. Класифікація зображень за допомогою ЗНМ – Codeguida: веб-сайт. URL: <https://codeguida.com/post/1400>(дата звернення: 25.05.2023).
23. WhatisKaggle – Kaggle: веб-сайт. URL: <https://www.datacamp.com/blog/what-is-kaggle>(дата звернення: 25.05.2023).
24. Inception-v3 for flower classification – Ieexplore:веб-сайт. URL: <https://ieeexplore.ieee.org/abstract/document/7984661>(дата звернення: 26.05.2023).
25. Exposing Computer Generated Images by Eye’s Region Classification via Transfer Learning of VGG19 CNN –Ieexplore:веб-сайт. URL: <https://ieeexplore.ieee.org/abstract/document/8260745>(дата звернення: 26.05.2023).
26. Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks – Link.Springer: веб-сайт. URL: <https://link.springer.com/article/10.1007/s42979-020-0114-9>(дата звернення: 26.05.2023).
27. Закон України «Про небезпечні та шкідливі виробничі фактори. Класифікація»/ Законодавство України про охорону праці. – К. Нова редакція 2002 р.
28. . ДСТУ ОHSAS 18002:2015. Системи управління гігієною та безпекою праці. Основні принципи виконання вимог ОHSAS 18001:2007 (ОHSAS 18002:2008, IDT). К. : ГП «УкрНИУЦ», 2016. 21 с.
29. ДСН 3.3.6.042-99 Санітарні норми мікроклімату виробничих приміщень. - [Електронний ресурс] - Режим доступу: <http://mozdocs.kiev.ua/view.php?id=1972>
30. Гігієнічна класифікація праці (за показниками шкідливості і небезпеки факторів виробничого середовища від 12.08.1986 № 4137-86. - [Електронний ресурс] - Режим доступу: <http://zakon4.rada.gov.ua/laws/show/v4137400-86>
31. ДБН В.2.5-28-2018 Природне і штучне освітлення - [Електронний ресурс] - Режим доступу: <http://document.ua/prirodne-i-shtuchne-osvitlennja-nor8425.html>
32. ДСН 3.3.6.037-99 Санітарні норми виробничого шуму, ультразвуку та інфразвуку. - [Електронний ресурс] - Режим доступу: <http://document.ua/sanitarni-normi-virobnichogo-shumu-ultrazvuku-ta-infrazvuku-nor4878.html>
33. ДСТУ 8604:2015 Дизайн і ергономіка. Робоче місце для виконання робіт у положенні сидячи. Загальні ергономічні вимоги. URL: http://online.budstandart.com/ua/catalog/doc-page?id_doc=71028.

34. Пожежна безпека об'єктів будівництва. Загальні вимоги. URL: http://www.poliplast.ua/doc/dbn_v.1.1-7-2002.pdf.

35. ДСТУ Б В.1.1-36:2016 Визначення категорій приміщень, будинків та зовнішніх установок за вибухопожежною та пожежною небезпек. URL: https://dbn.co.ua/load/normativy/dstu/dstu_b_v_1_1_36/5-1-0-1759.

36. НПАОП 0.00-7.15-18 Вимоги щодо безпеки та захисту здоров'я працівників під час роботи з екранними пристроями. URL: http://sop.zp.ua/norm_праор_0_00-7_15-18_01_ua.php

37. Наказ Міністерства внутрішніх справ України «Про затвердження Правил експлуатації та типових норм належності вогнегасників». URL: <https://zakon.rada.gov.ua/laws/show/z0225-18#Text>.

ДОДАТОК А

ФРАГМЕНТИ КОДУ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ ДЛЯ МОДЕЛІ

INCEPTIONV3

```

import numpy as np
import tensorflow as tf
import matplotlib.pyplot as plt
import os
from distutils.dir_util import copy_tree, remove_tree
from random import randint
from imblearn.over_sampling import SMOTE
from sklearn.model_selection import train_test_split
from sklearn.metrics import classification_report
import tensorflow_addons as tfa
from keras.utils.vis_utils import plot_model
from tensorflow.keras import Sequential, Input
from tensorflow.keras.layers import Dense, Dropout
from tensorflow.keras.layers import Conv2D, Flatten
from tensorflow.keras.callbacks import EarlyStopping
from tensorflow.keras.preprocessing.image import ImageDataGenerator as IDG
from tensorflow.keras.layers import SeparableConv2D, BatchNormalization,
MaxPool2D
print("TensorFlow Version:", tf.__version__)
##Data Pre-Processing
base_dir = "Alzheimer_s Dataset/"
root_dir = "./"
test_dir = base_dir + "test/"
train_dir = base_dir + "train/"
work_dir = root_dir + "dataset/"
# if os.path.exists(work_dir):
# remove_tree(work_dir)
#
# os.mkdir(work_dir)
# copy_tree(train_dir, work_dir)
# copy_tree(test_dir, work_dir)
print("Working Directory Contents:", os.listdir(work_dir))
WORK_DIR = './dataset/'
CLASSES = ['MildDemented',

```

```

'ModerateDemented',
'NonDemented',
'VeryMildDemented']
IMG_SIZE = 176
IMAGE_SIZE = [176, 176]
DIM = (IMG_SIZE, IMG_SIZE)
# Performing Image Augmentation to have more data samples
ZOOM = [.99, 1.01]
BRIGHT_RANGE = [0.8, 1.2]
HORZ_FLIP = True
FILL_MODE = "constant"
DATA_FORMAT = "channels_last"
work_dr = IDG(rescale=1. / 255, brightness_range=BRIGHT_RANGE,
zoom_range=ZOOM, data_format=DATA_FORMAT,
fill_mode=FILL_MODE, horizontal_flip=HORZ_FLIP)
train_data_gen=work_dr.flow_from_directory(directory=WORK_DIR,
target_size=DIM, batch_size=6500, shuffle=False)
# Display Train Images
def show_images(generator, y_pred=None):
    """
    Input: An image generator, predicted labels (optional)
    Output: Displays a grid of 9 images with labels
    """
    # get image labels
    labels = dict(zip([0, 1, 2, 3], CLASSES))
    # get a batch of images
    x, y = generator.next()
    # display a grid of 9 images
    plt.figure(figsize=(10, 10))
    if y_pred is None:
        for i in range(9):
            ax = plt.subplot(3, 3, i + 1)
            idx = randint(0, 6400)
            plt.imshow(x[idx])
            plt.axis("off")
            plt.title("Class: {}".format(labels[np.argmax(y[idx])]))
    else:
        for i in range(9):

```

```

ax = plt.subplot(3, 3, i + 1)
plt.imshow(x[i])
plt.axis("off")
plt.title("Actual: {} \n Predicted: {}".format(labels[np.argmax(y[i])],
labels[y_pred[i]]))
plt.show()
show_images(train_data_gen)
#Retrieving the data from the ImageDataGenerator iterator
train_data, train_labels = train_data_gen.next()
#Getting to know the dimensions of our dataset
print(train_data.shape, train_labels.shape)
#Performing over-sampling of the data, since the classes are imbalanced
sm = SMOTE(random_state=42)
train_data, train_labels = sm.fit_resample(train_data.reshape(-1, IMG_SIZE *
IMG_SIZE * 3), train_labels)
train_data = train_data.reshape(-1, IMG_SIZE, IMG_SIZE, 3)
print(train_data.shape, train_labels.shape)
#Splitting the data into train, test, and validation sets
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)
##Constructing a Convolutional Neural Network Architecture
def conv_block(filters, act='relu'):
    """Defining a Convolutional NN block for a Sequential CNN model. """
    block = Sequential()
    block.add(Conv2D(filters, 3, activation=act, padding='same'))
    block.add(Conv2D(filters, 3, activation=act, padding='same'))
    block.add(BatchNormalization())
    block.add(MaxPool2D())
    return block
def dense_block(units, dropout_rate, act='relu'):
    """Defining a Dense NN block for a Sequential CNN model. """
    block = Sequential()
    block.add(Dense(units, activation=act))
    block.add(BatchNormalization())
    block.add(Dropout(dropout_rate))
    return block

```

```

def construct_model(act='relu'):
    """Constructing a Sequential CNN architecture for performing the classification
    task. """
    model = Sequential([
        Input(shape=(*IMAGE_SIZE, 3)),
        Conv2D(16, 3, activation=act, padding='same'),
        Conv2D(16, 3, activation=act, padding='same'),
        MaxPool2D(),
        conv_block(32),
        conv_block(64),
        conv_block(128),
        Dropout(0.2),
        conv_block(256),
        Dropout(0.2),
        Flatten(),
        dense_block(512, 0.7),
        dense_block(128, 0.5),
        dense_block(64, 0.3),
        Dense(4, activation='softmax')
    ], name="cnn_model")
    return model

# Defining a custom callback function to stop training our model when accuracy goes
above 99%
class MyCallback(tf.keras.callbacks.Callback):
    def on_epoch_end(self, epoch, logs={}):
        if logs.get('val_acc') > 0.99:
            print("\nReached accuracy threshold! Terminating training.")
            self.model.stop_training = True
my_callback = MyCallback()

# EarlyStopping callback to make sure model is always learning
early_stopping = EarlyStopping(monitor='val_loss', patience=2)

# Defining other parameters for our CNN model
model = construct_model()
METRICS = [tf.keras.metrics.CategoricalAccuracy(name='acc'),
            tf.keras.metrics.AUC(name='auc'),
            tfa.metrics.F1Score(num_classes=4)]
CALLBACKS = [my_callback]
model.compile(optimizer='adam',

```



```

loss=tf.losses.CategoricalCrossentropy(),
metrics=METRICS)
model.summary()
##Training & Testing the Model
#Fit the training data to the model and validate it using the validation data
EPOCHS = 25
history = model.fit(train_data, train_labels, validation_data=(val_data, val_labels),
callbacks=CALLBACKS, epochs=EPOCHS)
#Evaluating the model on the data
test_scores = model.evaluate(test_data, test_labels)
#print("Training Accuracy: %.2f%%"%(train_scores[1] * 100))
#print("Validation Accuracy: %.2f%%"%(val_scores[1] * 100))
print("Testing Accuracy: %.2f%%"%(test_scores[1] * 100))
#Predicting the test data
pred_labels = model.predict(test_data)
#Print the classification report of the tested data
#Since the labels are softmax arrays, we need to roundoff to have it in the form of 0s
and 1s,
#similar to the test_labels
def roundoff(arr):
    """To round off according to the argmax of each predicted label array. """
    arr[np.argmax(arr) != arr.max()] = 0
    arr[np.argmax(arr) == arr.max()] = 1
    return arr
for labels in pred_labels:
    labels = roundoff(labels)
print(classification_report(test_labels, pred_labels, target_names=CLASSES))
#Saving the model for future use
# model_dir = work_dir + "alzheimer_cnn_model"
model_dir = "InceptionV3/alzheimer_cnn_model"
model.save(model_dir, save_format='h5')
os.listdir(work_dir)
pretrained_model = tf.keras.models.load_model(model_dir)
# Function to load and preprocess a single image
def load_and_preprocess_image(image_path):
    image = tf.keras.preprocessing.image.load_img(image_path,
target_size=IMAGE_SIZE)
    image = tf.keras.preprocessing.image.img_to_array(image)

```

```

image = image / 255.0 # Normalize image
image = np.expand_dims(image, axis=0) # Add batch dimension
return image
# Function to predict class and confidence
def predict_image(image_path):
    image = load_and_preprocess_image(image_path)
    predictions = model.predict(image)
    predicted_class_index = np.argmax(predictions)
    predicted_class = CLASSES[predicted_class_index]
    confidence = np.max(predictions) * 100
    return predicted_class, confidence
# Path to the image you want to test
image_path = 'Alzheimer_s Dataset/test/ModerateDemented/29 (2).jpg'
# Display the predicted class and confidence
predicted_class, confidence = predict_image(image_path)
print("Predicted Class:", predicted_class)
print("Confidence:", confidence)

```

ДОДАТОК Б

ФРАГМЕНТИ КОДУ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ ДЛЯ МОДЕЛІ VGG19

```

import matplotlib.pyplot as plt
import tensorflow_addons as tfa
import numpy as np
from tensorflow.keras.layers import Dense, Flatten
from tensorflow.keras.models import Model
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow import keras
import tensorflow as tf
from tensorflow.keras.applications.vgg19 import VGG19 # VGG19
#define image dataset
from tensorflow.keras.callbacks import ModelCheckpoint
image_generator=ImageDataGenerator(rescale=1/255, validation_split=0)
train_dataset = image_generator.flow_from_directory(batch_size=16,
directory='Alzheimer_s Dataset/train',
shuffle=True,
target_size=(224,224),
subset="training",
class_mode='categorical')
image_generator = ImageDataGenerator(rescale=1/255,validation_split=0.2)
validation_dataset = image_generator.flow_from_directory(batch_size=16,
directory='Alzheimer_s Dataset/test',
shuffle=True,
target_size=(224,224),
class_mode='categorical')
submission = image_generator.flow_from_directory(
directory='Alzheimer_s Dataset/test',
shuffle=False,
subset="validation",
target_size=(224,224),
class_mode=None)
#show flwoers for the first batch
batch_1_img = train_dataset[0]
for i in range(0,2):
img = batch_1_img[0][i]

```

```

lab = batch_1_img[1][i]
plt.imshow(img)
plt.title(lab)
plt.axis('off')
plt.show()
vgg = VGG19(input_shape=(224,224,3), weights='imagenet', include_top=False)
for layer in vgg.layers:
    layer.trainable = False
x = Flatten()(vgg.output)
prediction = Dense(4, activation='softmax')(x)
modelvgg = Model(inputs=vgg.input, outputs=prediction)
modelvgg.summary()
modelvgg.compile(optimizer='adam',
loss=tf.losses.CategoricalCrossentropy(),
metrics=[keras.metrics.AUC(name='auc'),'acc', tfa.metrics.F1Score(num_classes=4)])
# Define the checkpoint filepath
checkpoint_filepath = 'VGG19/model_checkpoint.h5'
# Define the ModelCheckpoint callback
checkpoint_callback = ModelCheckpoint(
    filepath=checkpoint_filepath,
    monitor='val_loss',
    mode='min',
    save_best_only=True,
    save_weights_only=False,
    verbose=1
)
callback = keras.callbacks.EarlyStopping(monitor='val_loss',
patience=8,
restore_best_weights=True)
modelvgg.fit(train_dataset, epochs=20, validation_data=validation_dataset,
callbacks=callback)
loss, auc, accuracy, f1_score = modelvgg.evaluate(validation_dataset)
print("Loss: ", loss)
print("AUC: ", auc)
print("Accuracy: ", accuracy)
print("F1 Score: ", f1_score)
# Path to the image you want to test
image_path = 'Alzheimer_s Dataset/test/ModerateDemented/29 (2).jpg'

```

```

# Function to load and preprocess a single image
def load_and_preprocess_image(image_path):
    image = tf.keras.preprocessing.image.load_img(image_path, target_size=(224,
224))
    image = tf.keras.preprocessing.image.img_to_array(image)
    image = image / 255.0 # Normalize image
    image = np.expand_dims(image, axis=0) # Add batch dimension
    return image

# Load and preprocess the image
input_image = load_and_preprocess_image(image_path)

# Make predictions on the image
predictions = modelvgg.predict(input_image)
class_index = np.argmax(predictions[0])
class_confidence = predictions[0][class_index]

# Get the class label from the dataset
class_label = train_dataset.class_indices
class_label = dict((v, k) for k, v in class_label.items())
class_name = class_label[class_index]

# Print the predicted class and confidence
print("Predicted Class:", class_name)
print("Confidence:", class_confidence)

```

ПРОТОКОЛ
ПЕРЕВІРКИ КВАЛІФІКАЦІЙНОЇ РОБОТИ
НА НАЯВНІСТЬ ТЕКСТОВИХ ЗАПОЗИЧЕНЬ

Назва роботи: Метод обробки та аналізу МРТ-зображень для виявлення хвороби Альцгеймера

Тип роботи: БКР

Підрозділ: кафедра біомедичної інженерії та оптико-електронних систем

Показники звіту подібності Unichesk

Оригінальність 98,9 %

Схожість 1,1 %

☒ 1. Запозичення, виявлені у роботі, оформлені коректно і не містять ознак плагіату.

☐ 2. Виявлені у роботі запозичення не мають ознак плагіату, але їх надмірна кількість викликає сумніви щодо цінності роботи і відсутності самостійності її виконання автором. Роботу направити на розгляд експертної комісії кафедри.

☐ 3. Виявлені у роботі запозичення є недобросовісними і мають ознаки плагіату та/або в ній містяться навмисні спотворення тексту, що вказують на спроби приховування недобросовісних запозичень.

Особа, відповідальна за перевірку



Штофель Д. Х.

Ознайомлені з повним звітом подібності, який був згенерований системою Unichesk щодо роботи.

Автор роботи



Шевчук І. А.

Керівник роботи



Карась О. В.