

Кафедра Системотехніки

КВАЛІФІКАЦІЙНА РОБОТА

Пояснювальна записка

Застосування згорткової нейронної мережі для обробки та аналізу МРТ-зображень

Виконав:

Ше́мет Серге́й Віта́лійович

Спеціальність 122 – Комп'ютерні науки

Тип програми освітньо-професійна

Освітня програма Інформаційні

технології проектування

Керівник: проф. Мінухін С. В.

Допускається до захисту

Зав. кафедри, проф.

2022 p.

Гребеннік І. В.

Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук _____
 Кафедра _____ Системотехніки _____
 Рівень вищої освіти _____ другий (магістерський) _____
 Спеціальність _____ 122 – Комп'ютерні науки _____
 Тип програми _____ освітньо-професійна _____
 Освітня програма _____ Інформаційні технології проектування _____

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
 (підпис)

«_____» _____ 20__ р.

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові Шемету Сергію Віталійовичу

1. Тема роботи Застосування згорткової нейронної мережі для обробки та аналізу МРТ-зображень
 затверджена наказом по університету від «» листопа 2022 р. № 629Ст
2. Термін подання студентом роботи до екзаменаційної комісії «23» грудня 2022 р.
3. Вихідні дані до роботи розробити метод класифікації МРТ зображень головного мозку для діагностики раку, середовище розробки MS Visual Studio 2022, мова програмування C#, фреймворк .Net 6, ML.NET середовище розробки Visual Studio Code, мова програмування TypeScript, фреймворк Angular,
4. Перелік питань, що потрібно опрацювати в роботі вступ, аналіз предметної області, огляд методів та технологій для проведення аналізу медичних зображень, постановка задачі дослідження, опис прийнятих програмних рішень формування.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Аналіз предметної галузі	10.10.2022-14.10.2020	виконано
2	Розробка специфікацій ПЗ	14.10.2022-18.10.2022	виконано
3	Об'єктний аналіз поставленої задачі	18.10.2022-21.10.2022	виконано
4	Створення коду програми	21.10.2022-10.11.2022	виконано
5	Тестування і налагодження програми	10.11.2022-15.11.2022	виконано
6	Підготовка пояснювальної записки	15.11.2022-20.12.2022	виконано
7	Підготовка презентації та доповіді	20.12.2022-22.12.2022	виконано
8	Нормоконтроль, рецензування	21.12.2022-22.12.2022	виконано
9	Попередній захист	22.12.2022	виконано
10	Занесення диплома в електронний архів	23.12.2022	виконано
11	Допуск до захисту у зав. кафедри	23.12.2022	виконано

Дата видачі завдання «10» жовтня 2022р.

Студент _____

(підпис)

Шемет С. В.

Керівник роботи _____ проф. Мінухін С. В.

(підпис)

(посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка до кваліфікаційної роботи магістра: 75 стор., 30 рис., 3 табл., 16 джерел, 2 додатка.

ВЕБ-СИСТЕМА, ГОЛОВНИЙ МОЗОК, КЛАСИФІКАЦІЯ, МОДЕЛЬ, МРТ, НЕЙРОННА МЕРЕЖА, ПРОГРАМНА СИСТЕМА, APS.NET CORE, BRAIN TUMOR, C#, ML.NET, MobilenetV2, WEB API.

Об'єктом дослідження є сучасні технології обробки, аналізу та дослідження МРТ-зображень для медичної діагностики.

Метою роботи є розробка ресурсоефективної та високоточної моделі машинного навчання для бінарної класифікації МРТ-зображень головного мозку.

В результаті роботи була спроектована програмна система, яка використовує модель машинного навчання MobilenetV2 для бінарної класифікації МРТ-зображень головного мозку для виявлення пухлин. Точність класифікації складає 98.07%.

ABSTRACT

Explanatory note to the Master's thesis: 75 pages, 30 figures, 2 tables, 16 sources, 3 attachments.

WEB SYSTEM, BRAIN, CLASSIFICATION, MODEL, MRI, NEURAL NETWORK, SOFTWARE SYSTEM, APS.NET CORE, BRAIN TUMOR, C#, ML.NET, MobilenetV2, WEB API.

The object of research is modern technologies of processing, analysis and research of MRI images for medical diagnostics.

The aim of the work is to develop a resource-efficient and highly accurate machine learning model for binary classification of brain MRI images.

As a result of the work, a software system was designed that uses the MobilenetV2 machine learning model for binary classification of brain MRI images for tumor detection. The classification accuracy is 98.07%.

ЗМІСТ

Вступ.....	8
1 Аналіз предметної області та постановка задачі	10
1.1 Діагностика онкологічних захворювань	10
1.2 Роль медичних зображень в діагностиці онкології.....	13
1.2.1 Рентгенівські зображення	13
1.2.2 Зображення МРТ	15
1.2.3 Зображення КТ	16
1.2.4 Зображення УЗД.....	18
1.3 Застосування штучного інтелекту та машинного навчання в аналізі медичних зображень	19
1.4 Постановка задачі.....	21
2 Огляд методів та технологій для класифікації зображень	25
2.1 Методи та технології аналізу зображень	25
2.2 Класифікація зображень	27
2.3 Штучні нейронні мережі	28
2.4 Згорткові нейронні мережі	33
2.5 Машинне навчання в класифікації зображень	37
2.6 Методи оцінки ефективності розпізнавання при класифікації	39
2.7 Аналіз існуючих архітектур згорткових мереж для класифікацій зображень....	43
2.7.1 Архітектура ResNet.....	43
2.7.2 Архітектура Inception.....	45
2.7.3 Архітектура MobileNet	47
3 Опис прийнятих програмних рішень.....	49
3.1 Обґрунтування вибору платформи та мови програмування.....	49
3.2 Опис інтерфейсу користувача для застосування розробленого методу	51

3.3 Архітектура згорткової нейронної мережі MobilenetV2 для класифікації MPT зображень	53
3.4 Навчання моделі MobileNetV2.....	57
3.5 Аналіз отриманих результатів	58
Висновки	59
Перелік джерел посилання	60
Додаток А.....	62
Додаток Б.....	67
Додаток В	68

ВСТУП

Проведення медичної діагностики для виявлення захворювань є першочерговою задачею сучасної медицини. Кожна людина упродовж усього свого життя потребує якісних та своєчасних медичних послуг, одним із найважливіших аспектів яких є діагностування захворювань, адже правильний і своєчасний діагноз може мати великий вплив на результат запровадженого лікувального процесу.

Одним з основних методів медичної діагностики захворювання є створення різних видів медичних зображень (КТ, МРТ, рентгенівські) для подальшої ручної або автоматизованої обробки та аналізу.

Аналіз медичних зображень – це трудомісткий процес, що вимагає граничної уважності та професіоналізму від фахівця, а також певних часових витрат. У багатьох випадках швидка та своєчасна діагностика може значною мірою полегшити та прискорити процес одужання пацієнта.

Аналіз медичних зображень використовується як основний метод діагностики багатьох онкологічних захворювань.

Онкологія є патологічним зростанням клітин, розподіл яких відбувається навіть за браку поживних речовин і місця зростання пухлини. Злоякісні клітини мають змінену форму, не підкоряються сигналам організму, не виконують своїх функцій і швидко поширюються тілом, формуючись у патологічні новоутворення. Рак є однією з основних причин смертності з медичних причин у всьому світі і вражає людей різного віку, від новонароджених дітей до людей похилого віку.

«Пухлина головного мозку вважається одним з найнебезпечніших захворювань, серед дітей і дорослих. Пухлини головного мозку складають від 85 до 90 відсотків усіх первинних пухлин центральної нервової системи (ЦНС). Щороку приблизно у 11 700 людей діагностують пухлину мозку. 5-річна виживаність людей із раковою пухлиною мозку або ЦНС становить приблизно 34 відсотки для чоловіків і 36 відсотків для

жінок. Пухлини головного мозку класифікуються як: доброякісна пухлина, злоякісна пухлина, пухлина гіпофіза тощо» [1].

Щоб збільшити тривалість життя пацієнтів, слід проводити належне лікування, планування та точну діагностику. Найкращим методом виявлення пухлин головного мозку є магнітно-резонансна томографія (МРТ). За допомогою сканування створюється величезна кількість даних зображення. Ці зображення перевіряє рентгенолог. Ручне обстеження може бути схильним до помилок через рівень складності пухлин головного мозку та їх властивості.

Пухлини головного мозку є складними. Існує багато відхилень у розмірах і локалізації пухлини головного мозку. Це дуже ускладнює повне розуміння природи пухлини. Також потрібен професійний нейрохірург для проведення МРТ дослідження. Часто в країнах, що розвиваються, брак досвідчених лікарів і знань про пухлини робить створення звітів за допомогою МРТ справді складним і трудомістким». Тому автоматизована система в хмарі може вирішити цю проблему.

Застосування методів автоматизованої класифікації з використанням машинного навчання (ML) і штучного інтелекту (AI) постійно демонструє вищу точність, ніж класифікація вручну. Таким чином, пропозиція системи, що виконує виявлення та класифікацію за допомогою алгоритмів глибокого навчання з використанням згорткової нейронної мережі (CNN), штучної нейронної мережі (ANN) і трансферного навчання (TL), була б корисною для лікарів у всьому світі.

Метою роботи є розробка ресурсоефективної та високоточної моделі машинного навчання для бінарної класифікації МРТ-зображень головного мозку.

1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ

1.1 Діагностика онкологічних захворювань

«Сьогодні онкологічні захворювання – це одна з основних проблем здоров'я в усьому світі. За даними Міжнародного агентства по дослідженню раку (IARC), було зареєстровано 8,2 млн. смертей рак у 2012 році та 27 мільйонів нових випадків захворювання очікується, відбудеться до 2030 року.

Серед типів раку, рак мозку складає 1–6 % від усіх новоутворень, які виникають в організмі людини. Пухлина головного мозку, на відміну від утворень інших органів, знаходиться в обмеженому інтракраніальному просторі. На рисунку 1.1 зображена статистика по раку мозку від Національного інституту раку за 2012-2018 роки.» [2]




Рисунок 1.1 – Статистика по раку головного мозку

Пухлиною головного мозку називають скупчення аномальних клітин, які вирізняються швидким поділом і зростанням. Вони рідко ширяться на інші частини

тіла, але більшість із них можуть поширюватися через тканини мозку. Небезпека даного типу пухлин полягає в порушенні основних функцій мозку.

Існує понад 130 видів раку головного мозку. Класифікують їх залежно від того, наскільки швидко вони ростуть і який ступінь ймовірності рецидиву після проведеного лікування.

Доброякісні пухлини мозку, 1 або 2 ступеня злоякісності, характеризуються відносно повільним зростанням і рідше повертаються після лікування. Доброякісні новоутворення в головному мозку, які рідко загрожують життю розвиваючись в інших частинах тіла, можуть в міру зростання тиснути на здорові тканини мозку і руйнувати їх, що може призвести до серйозних, а іноді і небезпечних для життя ушкоджень.

Злоякісні пухлини мозку 3 або 4 ступеня злоякісності можуть розвиватися безпосередньо в мозку (первинні пухлини) або метастазувати туди від пухлини в іншій частині тіла (вторинні пухлини), а також мають підвищену вірогідність рецидиву. Найчастіше метастази в мозок дають пухлини легенів, молочних залоз, колоректальний рак, рак нирок і меланому шкіри.

Діагноз «пухлина головного мозку» досить важко поставити через симптоматику, що може вказувати на інші захворювання.

Виділяють два основних типи пухлин головного мозку – доброякісні та злоякісні.

При підозрі на наявність пухлини мозку пацієнту призначають такі дослідження:

- комп'ютерна томографія;
- магнітно-резонансна томографія;
- позитронно-емісійна томографія;
- однофотонна емісійна КТ.

Незважаючи на значний прогрес, досягнутий діагностичними технологіями, фінальний діагноз раку головного мозку, включаючи класифікацію та постановку

діагнозу, робиться виключно медичними спеціалістами, що застосовують візуальний огляд медичних зображень.

«На сьогоднішній день найбільш найпоширенішим методом прийняття рішення рішень під час проведення медичного діагностування пацієнта є метод дискримінантного аналізу.

Дискримінантний аналіз полягає в вирішені задачі класифікації шляхом розрізнення об'єктів спостереження за відповідними ознаками. Точність класифікації для даного аналізу визначається в відсотках правильно класифікованих об'єктів за допомогою прогностичного рівняння спостережень. За умов коли початкова вибірка даних має велику розмірність, тоді аналіз проводиться лише для частини даних. Для іншої половини даних класифікація об'єктів спостережень відбувається за прогностичним рівнянням, побудованим за екземплярами першої частини.» [3]

Втім існує прив'язка до попереднього досвіду медичного спеціаліста, що в деяких випадках може призвести до помилок в діагностиці, а також суб'єктивною оцінювання отриманих медичних даних експертом.

Останні досягнення у технології обробки зображень та машинного навчання дозволяють будувати Системи автоматичного виявлення / діагностики (CAD / CADx) що може допомогти медичним спеціалістам бути більш продуктивними та об'єктивними і послідовними в діагностиці.

1.2 Роль медичних зображень в діагностиці онкології

Існуючі методи інструментальної діагностики в онкології тісно зв'язані з отримання різного роду медичних зображень. Ці зображення можливо згрупувати за методами їх отримання наступним чином:

- рентгенологічні зображення;
- магнітно-резонансно томографічні зображення (МРТ);
- ультразвукографічні зображення (УЗД).

Кожне зображення з перерахованих вище методів можливо використовувати для діагностування різних видів онкологій, але дані методи мають свої особливості застосування та певні плюси та мінуси використання.

1.2.1 Рентгенівські зображення

Рентгенологічний метод — це засіб вивчення будови та функції різноманітних органів та систем, що базується на кількісному та якісному аналізі пучка рентгенівського випромінювання, що пройшло крізь тіло людини.

Щоб отримати диференційоване зображення тканин, що приблизно однаково поглинають випромінювання, використовують штучне контрастування. З цією метою в організм вводять сполуки, які поглинають рентгенівське випромінювання сильніше або, навпаки, слабше, ніж м'які тканини, і таким чином створюють достатній контраст з органом, що вивчається. Сполуки, що затримують більше випромінювання, ніж м'які тканини, називають рентгенопозитивними.

Слід пам'ятати, що рентгенівський знімок є негативом по відношенню до зображення на флуоресцентному екрані при просвічуванні, тому прозорі для

рентгенівських променів ділянки тіла на рентгенограмі виглядають темними (затемнення), а більш щільні — світлими (просвітлення). Кожен промінь при проходженні крізь тіло людини перетинає не одну, а велику кількість точок, розташованих як на поверхні, так і в глибині тканин. Відповідно, кожній точці на знімку відповідає множина дійсних точок об'єкту, котрі проектуються одна на іншу, і тому рентгенівське зображення є сумаційним, пласким. Із цього слідує головне правило рентгенологічних досліджень: рентгенограми будь-якої частки тіла повинні бути проведені щонайменше у двох взаємно перпендикулярних проекціях — прямій та боковій, приклад зображено на рисунку 1.2. Як додаток, можуть знадобитися знімки у косих та аксіальних проекціях.



Рисунок 1.2 – Рентгенівський знімок голови

Низька вартість та значна пропускну здатність дозволили використовувати рентгенологічний метод як скринінгову методику масового профілактичного дослідження населення в державній програмі раннього виявлення туберкульозу і раку легені, що ефективно діяла за часів Радянського Союзу. Проте низька розподільча здатність та відносно велике променеве навантаження при традиційній плівковій флюорографії зумовили відмову від неї в країнах Європейської спільноти.

1.2.2 Зображення МРТ

МРТ — томографічний метод дослідження внутрішніх органів та тканин за допомогою використання фізичного явища ядерно-магнітного резонансу (ЯМР). Метод базується на вимірюванні електромагнітного відклику ядер атомів водню у відповідь на збудження їх визначеною комбінацією електромагнітних хвиль у постійному магнітному полі високої напруги. Приклад МРТ знімку зображено на рисунку 1.3.




Рисунок 1.3 – МРТ знімок з пухлиною головного мозку

«Метод МРТ дозволяє вивчати організм людини на основі насиченості тканин воднем та особливостей їх магнітних властивостей, пов'язаних із розташуванням в оточенні різних атомів та молекул. Ядро водню складається з одного протону, котрий має магнітний момент (спін) та змінює свою просторову орієнтацію у потужному магнітному полі, а також при впливі додаткових полів, що мають назву градієнтних, та зовнішніх радіохвильових імпульсів, що подаються на специфічній для протону у даному магнітному полі резонансній частоті. При дії на досліджувану ділянку електромагнітним випромінюванням заданої частоти частина протонів змінить свій магнітний момент на протилежний, а потім повернеться в попередній стан. При цьому системою збору даних реєструється виділення енергії під час релаксації попередньо збуджених протонів» [4].

Основними магнітно-резонансними характеристиками об'єктів вважають 3 параметри: щільність протонів, час T1 та час T2. T1 називають спін-поздовжньою релаксацією, а T2 — спін-поперечною релаксацією. Амплітуда зареєстрованого сигналу характеризує щільність протонів, або, що те саме, концентрацію елементу у середовищі, що вивчається. Щодо часу T1 та T2, то ці показники залежать від багатьох факторів (молекулярна структура речовини, температура, в'язкість та ін.). Принципово для МРТ можливо використовувати не тільки ядра водню, але й ядра інших атомів, що здатні генерувати магнітно-резонансні сигнали. Проте їх концентрація у тканинах значно нижча, відповідно, нижчі чутливість методу та якість зображення.

1.2.3 Зображення КТ

«Комп'ютерна томографія — метод рентгенівського сканування, при якому пучок рентгенівського променя пошарово та поступово проходить через тонкий шар тканин людського тіла в різних напрямках. У вузькому сенсі (в якому вживається значно частіше), синонім терміну рентгенівська комп'ютерна томографія, оскільки саме цей метод поклав початок сучасній томографії. З її допомогою можна визначити стан будь-якого органу людини, його розміри, положення, форму, стан поверхні, його функції та щільність. За допомогою КТ можна переглянути навіть будову системи кровообігу» [5].

Отримані зображення КТ, приклад який зображено на рисунку 1.4, повинен вивчити лікар-радіолог (лікар, який спеціалізується на КТ, МРТ, Рентген-дослідженнях, що має відповідний сертифікат). Необхідно «прочитати» всі скани, вивчити надану мед. документацію, зіставити її з отриманою КТ-картиною, описати

дослідження, вивести діагностичний висновок, відзняти плівку зі скані. В середньому це займає близько 1-3 годин.




Рисунок 1.4 – КТ знімок головного мозку

Сучасний комп'ютерний томограф є складним програмно-технічним комплексом. Механічні вузли та деталі виконані з найвищою точністю. Для реєстрації рентгенівського випромінювання, що пройшло через середовище, використовуються надчутливі детектори. Конструкція та матеріали, які застосовуються при їх виготовленні, постійно вдосконалюються. При виготовленні комп'ютерного томографа висуваються найжорсткіші вимоги до рентгенівських випромінювачів. Невід'ємною частиною апарату є великий пакет програмного забезпечення, що дозволяє проводити весь спектр комп'ютерно-томографічних досліджень (КТ-досліджень) з оптимальними параметрами, проводити подальшу обробку та аналіз КТ-зображень.

З математичної погляду побудова зображення зводиться до розв'язання системи лінійних рівнянь. Так, наприклад, для отримання томограми розміром 200 200 пікселів система включає 40 000 рівнянь. Для вирішення подібних систем розроблено спеціалізовані методи, що базуються на паралельних обчисленнях.

1.2.4 Зображення УЗД

Ультрасонографічне дослідження — неінвазійне дослідження положення, форми, розміру, структури, руху органів, тканин та патологічних вогнищ організму людини за допомогою ультразвукових хвиль.

Ультразвукові хвилі — це пружні коливання середовища з частотою більше ніж 20 КГц. Ультразвукові методи, що застосовуються у медицині, розділяють на скринінгові, базові та спеціалізовані (експертні).

Скринінгові процедури розраховані на виділення патологічних ділянок на фоні нормальної тканини.

Спеціалізовані дослідження виконуються із застосуванням внутрішньопорожнинних датчиків (ректального, вагінального, стравохідного), високочутливих кардіосудинних датчиків, датчиків для виконання пункційної біопсії.

Ультразвукове сканування дозволяє отримати двовимірне зображення органів (сонографія), приклад якого зображено на рисунку 1.5. В основі методу лежить пересування ультразвукового пучка по поверхні тіла пацієнта під час дослідження. Це забезпечує реєстрацію сигналів одномоментно або послідовно від багатьох об'єктів.



Рисунок 1.5 – Знімок УЗД головного мозку

«При ультразвуковому скануванні яскравість кожної точки на екрані знаходиться у прямій залежності від інтенсивності ехосигналу. Оптимальним

вважається наявність не менше 64 градієнтів чорно-білої шкали. При позитивній реєстрації максимальна інтенсивність ехосигналів проявляється на екрані білим кольором (ехопозитивні ділянки), а мінімальні — чорним (ехонегативні ділянки). При негативній реєстрації відмічають протилежне положення. Вибір позитивної чи негативної реєстрації не має суттєвого значення» [6].

Зображення, що отримується при дослідженні, може бути різним залежно від режиму роботи сканера. Виділяють наступні режими:

В-режим — найчастіше використовують при дослідженні, при цьому інформація, що отримується датчиками, оброблюється сканером у реальному часі і на основі отриманої інформації будується картинка, яка представляє зріз об'єкта, що вивчають.

Д-режим — при цьому режимі використовується ефект Допплера, названий так на честь австрійського вченого — фізика та астронома. В його основі лежить зміна довжини хвилі (або частоти) при русі джерела хвиль відносно пристрою, який приймає їх.

Частота звуку, що випромінює рухомий об'єкт, змінюється залежно від його швидкості. Апарат реєструє різницю між частотою ультразвуку, що випромінює датчик, і частотою відбитого сигналу і перевтілює цю інформацію у візуальну картину. Цей ефект характерний для будь-яких хвиль (світло, звук тощо). При приближенні джерела до приймача довжина хвиль зменшується, при віддаленні — збільшується.

1.3 Застосування штучного інтелекту та машинного навчання в аналізі медичних зображень

Радіологи можуть приймати кращі рішення та підвищувати продуктивність при лікуванні пацієнтів за допомогою штучного інтелекту та машинного аналізу медичних зображень, що базується на навчанні. Вони можуть швидко знаходити та покращувати стан пацієнтів.

Тепер, коли галузь розуміє важливість технологій для процесу отримання медичних зображень, численні постачальники та технологічні експерти працюють над тим, щоб забезпечити медичну промисловість найкращими інструментами та додатками.

Це дозволяє підвищити якість інформації, доступної радіологам під час проведення аналізу, що забезпечує вищу точність. Зростання використання технологій ШІ та МН у галузі медицини покращує збір даних та складання підсумкових звітів. Рентгенологи можуть отримати доступ до історії хвороби пацієнта та переглянути результати попереднього лікування для проведення точного діагнозу. Навіть за складних медичних умов співпраця професійного рентгенолога із цими технологіями вирішує основні проблеми лікування хвороби.

Глибоко вивчені алгоритми можуть вивчити та виконати різні важливі завдання, щоб допомогти фахівцям у прийнятті рішень та ранній діагностиці захворювань. Вони можуть отримати доступ до нових та попередніх даних для забезпечення максимальної ефективності лікування. Це пояснює, чому технології штучного інтелекту та машинного навчання беруть штурмом галузь охорони здоров'я. Ось деякі з переваг, які ШІ та МН забезпечують для аналізу медичних зображень:

- за допомогою покращеного аналізу медичних зображень на основі ШІ та МН медичні експерти можуть підвищити продуктивність свого клінічного процесу та продуктивність праці;
- за допомогою машинного навчання ми можемо розробити модель, яка ефективно діагностуватиме такі захворювання, як пухлини або рак. Машинне навчання та технології ШІ працюють з використанням алгоритму, що знижує ймовірність помилок. Штучний інтелект може ідентифікувати ракові клітини по

багаточисельним медичним зображенням. Точність системи штучного інтелекту може становити аж до 99%, тоді як точність медичного працівника – 38%.

– Команди лікарів, оснащені системами аналізу медичних зображень на основі штучного інтелекту та машинного навчання, можуть приймати обґрунтовані та швидкі рішення, легко діагностувати захворювання та оптимізувати робочий процес: Це, зрештою, підвищує задоволеність пацієнтів та покращує їх досвід.

Нейромережі використовуються для вирішення основного спектру задач медичної діагностики: задач класифікації та кластеризації захворювань, прогнозування різноманітних епідеміологічних факторів. Дана популярність зумовлена тим, що нейромережі можуть бути використані не тільки як алгоритм для прийняття рішень по тому чи іншому пацієнту, а і як застосування для збору додаткових ознак із неструктурованих даних, таких як рентгенівські знімки чи записи кардіограми роботи серця.

Серед недоліків даного підходу слід виділити те, що для навчання нейромережі потрібні великі масиви даних та обчислювальні ресурси, але з розвитком хмарних технологій, зокрема архітектур збереження та обробки великих масивів даних, даний недолік стає все менш і менш помітним при практичному застосуванні.

1.4 Постановка задачі

Орієнтуючись на актуальність зображеної проблеми дослідження та важливості аналізу медичних зображень в процесі діагностування, а також широко розповсюдження різних методів інтелектуального аналізу за допомогою нейронних мереж робить наукові дослідження в сфері штучного інтелекту досить затребуваними.

Розглянуто у попередніх підрозділах методи аналізу медичних зображень та проаналізовано сферу та доцільність їх використання. Було прийнято рішення, що необхідно розробити алгоритм бінарної класифікації (класифікація на дві групи) медичних зображень, а саме знімків магнітно-резонансної томографії для діагностування раку головного мозку.

Метою даної роботи є дослідження та розробка методу класифікації ознак поділених на дві протилежних групи на медичних зображеннях. Метод повинен здійснювати класифікації ознак взявши за основу достовірну базу розподілених за ознаками даних.

Головними критеріями оцінки розробленого методу є:

- висока точність класифікації – більше 95%;
- отримання високої точності використавши мінімальну кількість даних для навчання – 2000 медичних зображень;

- висока швидкість класифікації – менше 500 мс.

Для розв’язку поставленої задачі необхідно:

- дослідити методи ідентифікації та класифікації характеристик об’єктів на медичних зображеннях;
- проаналізувати існуючі методи глибокого навчання в контексті застосування їх до медичних зображень;
- розробити алгоритм розпізнавання зображень магнітно-резонансної томографії на основі нейромережевого підходу;
- дослідити ефективність розробленого алгоритму на основі класифікації МРТ знімків.

Розроблений програмний метод буде використовуватись для проведення бінарної класифікації медичних МРТ-зображень головного мозку для виявлення пухлин. Дана задача є задачею бінарної класифікації, тобто цільова змінна буде набувати лише двох значень: наявність та відсутність пухлини відповідно.

Відповідно до цього, вхідні дані будуть представлятись у вигляді трьохканальних (RGB) кольорових МРТ-зображень. Вхідні зображення розподіляються на дві групи та помічаються відповідними семантичними мітками: уес або по.

Мітка уес означає, що на вхідному зображенні є специфічний кластер точок, який представляє собою пухлину. На вхідному зображенні, приклад якого зображено на рисунку 1.5, що відноситься для групи уес може бути розташовано один або декілька кластерів семантичних точок. Зазвичай семантичні точки організовують область здебільше округлої форми без гострих кутів. Колір семантичної точки знаходиться в діапазоні RGB значень кольорів від RGB(256, 256, 256) – білого до RGB(150, 130, 130) – темно-сірий.




Рисунок 1.5 – Приклад вхідного зображення класу YES

Мітка по означає, що на вхідному зображенні, приклад якого зображено на рисунку 1.6, відсутні кластери семантичних точок, які представляють собою одну або декілька пухлин головного мозку.




Рисунок 1.6 – Приклад вхідного зображення класу NO

Вихідними даними є результат класифікації (прогнозування) в вигляді структури даних, що має наступні параметри:

- назва вхідного файлу;
- клас, що визначений класифікатором (yes або no);
- вірогідність, що оцінена класифікатором, приналежності вхідного зображення визначеного класу;
- час виконання операції в мс.

2 ОГЛЯД МЕТОДІВ ТА ТЕХНОЛОГІЙ ДЛЯ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ

2.1 Методи та технології аналізу зображень

«Обробка й аналіз зображень – це покрокова процедура, що залежить від результатів попереднього етапу, а також знань і досвіду оператора. Фаза попередньої обробки покращує якість зображення, а фаза сегментації виділяє елементи, його складові, що в остаточному результаті покращує якість і точність діагностики» [7].

У наш час на зміну аналоговим приходять цифрові медичні зображення. Переведення в цифрову форму (із самого початку їхнього отримання) полегшує обробку зображень, зберігання й передачу медичних візуальних даних. Інформаційні технології можуть допомогти на всіх етапах отримання й обробки медичних зображень.

Комп'ютери безпосередньо приймають участь у створенні деяких типів зображень, які не можуть бути отримані іншим способом: комп'ютерна томографія, позитронна емісійна томографія (ПЕТ), ядерний магнітний резонанс.

Цифрова обробка зображення може використовуватися з метою:

- покращення якості зображення, компенсації дефектів системи, що реєструє, і зменшення шуму;
- розрахунку клінічно важливих кількісних параметрів (відстані, площі, об'єму, тощо);
- спрощення інтерпретації (розпізнавання структури, обчислення дози для променевої терапії);
- встановлення зворотного зв'язку (автоматизовані хірургічні втручання).

«Стиснення зображень зменшує об'єм пам'яті для зберігання даних і час для їх передачі. Зберігання переведених у цифрову форму зображень на твердих магнітних дисках або CD спрощують організацію архівів і доступ до них. Передача переведених у цифрову форму зображень між лікувальними установами дозволяє декільком

експертам швидко консультуватися для прийняття діагностичних або терапевтичних рішень і поліпшує контроль за лікуванням пацієнта (телерадіологія, телепатологія)» [8].

Можна виділити такі етапи обробки зображень:

- Попередня обробка. Фаза попередньої обробки усуває відхилення, пов'язані із системою генерації зображення, і зменшує шуми. Методи, що використовуються, обробляють за допомогою спеціальних програм цифрові дані й у такий спосіб поліпшують видимість де яких анатомічних структур.

- Зміна контрастності зображення. Розрахунок гістограми зображення створює подання кількості пікселів для кожного рівня сірого в зображенні. Якщо гістограма має нелінійний розподіл, то багато деталей буде втрачено. Операції по вирівнюванню гістограми покращують контрастність й, відповідно, відображення деталей.

- Сегментація. Ця фаза обробки зображення ізолює окремі елементи зображення (органи, клітини й т.д.). Метод заснований на ідентифікації однакових пікселів з допустимим рівнем похибки. Порівнянням двох різних за часом сегментованих зображень виявляють динаміку.

- Розрахунок параметрів. Розрахунок лінійних й об'ємних параметрів анатомічних утворень. Інтерпретація зображень.

Автоматична комп'ютерна інтерпретація поки ще залишається проблемою. Для її якісного виконання потрібна база знань з порівняльної та патологічної анатомії. Отримані структури й параметри повинні бути порівняні з відомими структурами й класифіковані.

2.2 Класифікація зображень

Класифікація зображень - одне із завдань у галузі Комп'ютерного зору (CV). Це використовується для вирішення проблеми присвоєння міток або категорій набору вхідних зображень. Крім того, інші завдання комп'ютерного зору, такі як виявлення об'єктів або сегментація, можуть бути зведені до класифікації зображень. Наприклад, розпізнавання того, чи зображений об'єкт на малюнку, наприклад, визначення дорожніх знаків та вуличних ліхтарів, або присутності кота.

Процес полягає у вилученні основних ознак та створенні моделі, яка вивчає витягнуті ознаки. Після навчання моделі, той самий екстрактор функцій використовується між моделлю та входом при передбаченні мітки, приклад зображено на рисунку 2.1.




Рисунок 2.1 – Процес розпізнавання зображення за допомогою витягнення ознак

Класифікація зображень може складатися з наступних етапів:

- підготовка даних;
- первинна обробка зображення: видалення шуму, технології корекції та ін.;
- виявлення важливих характеристик зображення;
- класифікація: зображення класифікуються в заздалегідь визначені категорії

на основі виявлених важливих характеристик.

2.3 Штучні нейронні мережі

Нейронна мережа – це математична модель, що була сконструйована на основі принципів роботи людського нейрона. Звідси походять і основні складові архітектури класичної нейронної мережі: нейрони, синапси та функції активації нейронів.

Розглянемо детальніше кожен із основних архітектурних елементів класичної нейронної мережі.

Нейрон – це обчислювальна одиниця, яка отримує інформацію, робить над нею прості обчислення і передає її далі. Вони діляться на три основні типи: вхідний, прихований і вихідний. У тому випадку, коли нейронмережа складається з великої кількості нейронів, вводять термін шару. Відповідно, є вхідний шар, який отримує інформацію, n прихованих шарів, які її обробляють і вихідний шар, який виводить результат. У кожного з нейронів є два основні параметри: вхідні дані і вихідні дані.

Говорячи про функції активації, слід розуміти, що кожна з них має свої переваги і недоліки, та може бути використана в залежності від тої чи іншої задачі, що ставиться перед побудовою нейронмережі. Розглянемо основні, найбільш часто вживані функції активації нейронів у нейронних мережах.

Однією з таких є ступінчата функція активації (2.1), що за своєю суттю є кусково-лінійною і визначається наступним чином:

$$\varphi(x, \alpha) = \begin{cases} 1, & x > \alpha \\ 0, & \text{в протилежному випадку} \end{cases} \quad (2.1)$$

Зокрема, частковим випадком даної функції є функція Хевісайда (2.2):

$$\mu(x) = \begin{cases} 1, & x > 0 \\ 0, & \text{в протилежному випадку} \end{cases} \quad (2.2)$$

Таким чином, при використанні даної функції, активований нейрон буде приймати значення 1, а неактивований – 0.

Дана функція активації знайшла досить широке використання у задачах бінарної класифікації – підвиду задач класифікації, де кількість класів, на які потрібно класифікувати об'єкт дорівнює двом. Водночас, така побудова функції унеможливорює її використання у задачах мультикласової класифікації, тобто коли кількість класів більше двох. Це обумовлено тим, що з використанням ступінчатої функції активації при мультикласовій класифікації, нейрон може бути активованим одночасно на декілька класів.

Класична нейронна мережа, базова архітектура якої зображена на рисунку 2.2, складається із сукупності цих складових і утворює структуру, де кожен прихований шар складається із множини нейронів, кожен з яких має зв'язок з усіма нейронами попереднього шару.




Рисунок 2.2 – Базова архітектура штучної нейронної мережі у порівнянні з людським нейроном

«Класифікація нейронних мереж за топологією:

– повно зв’язні мережі – кожен нейрон якої передає вихідний сигнал іншим нейронам, в тому числі і самому собі (рисунок 2.3, а), всі вхідні сигнали подаються до усіх нейронів;

– багатошарові або шаруваті мережі – зовнішні вхідні сигнали подаються на входи нейронів 1 шару (нульовий) виступають лише в якості розподільних точок, в проміжних (прихованих) шарах проходить підсумовування і перетворення сигналів, а виходами мережі є вихідні сигнали крайнього шару (рисунок 2.3, б);

– слабо зв’язані мережі – шаруваті мережі з малою кількістю зв’язків (рисунок 2.3, в)» [9].




Рисунок 2.3 – Архітектури нейронних мереж:

а – повнозв’язна мережа, б – багатошарова мережа з послідовними зв’язками, в – слабкозв’язана мережа

Перший шар нейронів називають «вхідним» шаром, кількість нейронів в якому залежить від розмірності вхідних даних, останній повнозв’язний шар нейронів (тобто такий шар, де кожен нейрон наступного шару зв’язаний з кожним нейроном

попереднього шару) називається вихідним шаром і у задачах класифікації він демонструє кількість класів, на яку ми хочемо «розбити» вхідну множину значень.

Слід також розглянути те, як проходить навчання нейромережі. Так як нейронні мережі є представником методів машинного навчання за прецедентами, то задача навчання зводиться до задачі мінімізації функціоналу помилки мережі.

Ключовою відмінністю навчання нейромереж від інших методів машинного навчання є те, що цей процес відбувається у два етапи:

- етап прямого розповсюдження помилки (forward propagation);
- етап зворотного розповсюдження помилки (back propagation).

Розглянемо більш детально кожен із етапів.

У процесі прямого розповсюдження помилки нейронна мережа розраховує прогнозний відклик моделі, шляхом поширення вхідного сигналу через всю архітектуру мережі, зображено на рисунку 2.4.

Далі, у процесі зворотного розповсюдження помилки, розраховується вклад кожного нейрона у загальне значення обраного функціоналу якості і тим самим відбувається корегування кожного із вагових коефіцієнтів нейронів.




Рисунок 2.4 – Алгоритм прямого розповсюдження помилки

У процесі зворотного розповсюдження, який зображено на рисунку 2.5, помилки розраховується значення функції помилки на даному об'єкті, і відображається вклад кожного вагового коефіцієнта шляхом знаходження частинної похідної функції помилки по відповідному ваговому коефіцієнту. Фактично, процес навчання нейромережі зводиться до послідовного застосування методу градієнтного спуску на кожному шарі нейронної мережі.




Рисунок 2.5 – Алгоритм зворотного розповсюдження помилки

Зауважимо, що під час проходження даного етапу навчання нейромережі, широко застосовується правило диференціювання складної функції (chain rule) (2.3):

$$y = f(u(x)) \rightarrow \frac{dy}{dx} = \frac{dy}{du} \frac{du}{dx} \quad (2.3)$$

Дані етапи навчання нейронної мережі проводяться ітеративно, певну кількість епох – циклів виконання алгоритму навчання, і, як результат, отримуються оптимальні значення вагових коефіцієнтів - гіперпараметрів нейромережі.

Використання класичних нейронних мереж при розв'язанні задачі класифікації зображень було досить поширеним, проте, з розвитком методів глибокого машинного навчання, з'явився більш спеціалізований метод, що використовується для класифікації зображень – згорткові нейронні мережі.

2.4 Згорткові нейронні мережі

Згорткові нейронні мережі (Convolutional Neural Network, CNN) – вид нейронних мереж, основним застосуванням яких є вирішення задач класифікації та сегментації зображень. Так як ці мережі є удосконаленням звичайних нейронна мереж, то вони мають деякі модифікації у своїй архітектурі.

Основними шарами таких нейронних мереж є: шар згортки (Convolutional Layer), шар субдискретизації (Pooling Layer), шар Dropout та «звичайний» повнозв'язний шар (Dense Layer) нейронів.

Розглянемо детальніше кожен із основних архітектурних шарів згорткових мереж.

Основою усієї нейромережі є шар «згортки» (convolution layer) і складається з «ядра згортки» – двовимірної матриці (частіше всього – розміром 3x3 або 5x5).

Процес «згортки» відбувається у такі етапи:

- вирахування скалярного добутку між ядром згортки та декодованою п-вимірною матрицею, що описує вхідне зображення;
- «зсув» ядра згортки на відповідний крок так, щоб вирахувати її скалярний добуток з тією частиною матриці вхідного зображення, яка не була використана на попередньому кроці.

Отже, упродовж перших двох етапів нейронна мережа сформує так звану «карту ознак» («feature map»), кількість цих карт залежить від кількості ядер згортки, кожне з яких описує певну ознаку, яка буде «відшукуватись» на вхідному зображенню, зображено на рисунку 2.6.




Рисунок 2.6 – Візуалізація роботи першого шару згортки розміром 5 x 5

На інших етапах згортки у якості вхідного зображення буде використовуватись та карта ознак, що була отримана на попередньому кроці.

Таким чином, на кожному наступному етапі згортки нейронна мережа буде вивчати все більш високоабстрактні закономірності, поки, врешті-решт, не зможе відрізнити такі поняття, як колір очей та форму обличчя, зображено на рисунку 2.7.




Рисунок 2.7 – Обробка кольорового зображення (RGB) розміром 32 x 32 вхідним шаром нейронів згорткової нейронної мережі

Наступним розглянемо шар субдескриптізації (Pooling layer). Цей шар використовується для зменшення розмірності карти ознак, яку ми отримали після шару згортки. Це робиться для того, щоб перешкодити перенавчанню нейронної мережі, а також вивченню нелокальних закономірностей, адже для подальшого вивчення зображення нам вже не потрібно знати точне місцеположення тієї чи іншої ознаки, важливим залишається лише факт її наявності на даній ділянці зображення.

Реалізація цього шару є досить простою: ми проходимося по карті ознак спеціальним «віконечком» – двовимірною матрицею (частіше всього – розміром 2×2), тобто на кожному кроці розглядаємо лише 4 значення, які знаходяться поруч на карті ознак, і вибираємо максимальне з них (через дану особливість цей шар ще називають max-pooling).

Досить часто використовувався й інший спосіб: average pooling – коли ми на кожному кроці проходимося по карті ознак двовимірною матрицею і беремо середнє значення від ознак, які потрапили у відповідне «віконце». Але на практиці даний метод показує дещо гірші результати ніж max-pooling.

Таким чином, на виході цього шару, ми отримуємо ту ж саму двовимірну карту ознак, але її розміри по ширині та довжині будуть менші від вхідних у 2 рази.

Отже, чергуючи шари згортки та пулінгу ми можемо виділити із нашого вхідного зображення основні ознаки та сформувати з них відповідні вектори ознак, які ще називають дескрипторами.

Принцип роботи наступного шару нейронної мережі – шар Dropout – полягає у тому, що на цьому кроці ми випадково «вимикаємо» певний відсоток нейронів (зазвичай береться 20%), тобто робимо так, що дані нейрони не реагують на ознаки, що є виходом попереднього шару. Цей метод використовується для того, щоб запобігти перенавчанню нейронної мережі та зменшити акцентування «уваги» нейронів на незначних, нетипових ознаках. Зазвичай даний шар використовують після Pooling шару.

Вихідним шаром в архітектурі згорткової нейронної мережі є повнозв'язний шар нейронів. Він використовується для обробки отриманих ознак із згорткових шарів.

Інакше кажучи з використання декількох шарів згортки, пулінгу та Dropout ми отримуємо багатовимірний вектор-стовпчик, кожна координата якого буде відповідати за деяку ознаку, що присутня на вхідному зображенні (це можуть бути певні градієнти кольорів, наявність паралельних ліній тощо). Далі, щоб власне класифікувати вхідне зображення (наприклад, визначити, котик це чи собака, або чи одна й та сама людина представлена на зображенні) потрібно використати повнозв'язний шар нейронів, який працює як «звичайна» нейронна мережа: на вхід кожного нейрона подається лінійна комбінація вагів та вхідних даних (у нашому випадку – ознаки, що отримані зі згорткових шарів), виходом нейрона буде та ж лінійна комбінація, «пропущена» через функцію активації даного нейрона.

Розмірність даного повнозв'язного шару (кількість нейронів у ньому) відповідає кількості класів, на які ми хочемо класифікувати вхідне зображення (у задачі про котиків та собак – 2).

Фактично, виходом k -го нейрона вихідного шару буде ймовірність того, що на вхідному зображенні представлено об'єкт k -го класу.

Приклад архітектури нейронної мережі показано на рисунку 2.8.




Рисунок 2.8 – Приклад CNN мережі

Дана мережа приймає чорно-біле вхідне зображення розміром 32 x 32 та складається з двох шарів згортки (розмірностями 6 x 28 x 28 та 16 x 10 x 10 відповідно), двох шарів пулінга, а також трьох повнозв'язних шарів нейронів (розмірностями 120, 84, та 10 відповідно).

Розмірність останнього повнозв'язного шару означає, що дана нейронна мережа розв'язує задачу класифікації зображень на 10 класів (які звичайно не перетинаються)

Отже, даний метод полягає у побудові спеціалізованої нейронної мережі для класифікації зображень.

2.5 Машинне навчання в класифікації зображень

Машинне навчання – розділ штучного інтелекту, що займається побудовою та вивченням методів, які здатні навчатися. Під «навчанням» методу у більшості випадків розуміють навчання за прецедентами, загальне формулювання якого полягає у наступному: по заданій скінченній множині об'єктів (прецедентів), які описуються деяким набором даних, що зібрані по кожному із об'єктів множини, потрібно виявити та відновити певні закономірності та взаємозв'язки. Сукупність таких об'єктів, із заданим характеристичним описом, часто називають навчальною вибіркою. Під час навчання за прецедентами фіксується функціонал якості – критерій, згідно якого буде проходити процес навчання і значення якого показує, наскільки добре побудована модель описує вхідні дані, та деяка сім'я моделей, з якої буде обиратись фінальний алгоритм – побудована модель. Сім'я моделей має свою варіативність, що задається різним набором параметрів моделі. Фінальний алгоритм, обраний у процесі навчання, буде приймати оптимальне значення функціоналу якості на навчальній вибірці.

Фактично, кожна задача навчання алгоритму машинного навчання зводиться до задачі оптимізації (як правило, мінімізації) деякого функціоналу якості на множині прецендентів, представлено в вигляді формули (2.4). Тобто, в результаті навчання алгоритму будуть підібрані такі параметри моделі машинного навчання, при яких обраний функціонал якості буде приймати оптимальне значення на множині об'єктів навчальної вибірки:

$$\vec{\alpha} = \operatorname{argmin}_{\vec{\alpha}} Q(X, \vec{\alpha}), \quad (2.4)$$

де – оцінюваний вектор гіперпараметрів моделі;

- обраний функціонал якості;
- задана навчальна вибірка.

Говорячи про типи задач навчання за прецендентами, розглядають такі основні їх види:

- навчання з учителем (supervised learning);
- навчання без учителя (unsupervised learning);
- навчання з підкріпленням (reinforcement learning);
- часткове навчання (semi-supervised learning).

Розглянемо підвид задач машинного навчання, що використовується для вирішення класифікації зображень – навчання з учителем, зображено на рисунку 2.9.




Рисунок 2.9 – Робота методу машинного навчання з учителем

Навчання з учителем характерне тим, що тренувальна вибірка, окрім об'єктів та їх характеристичних описів містить ще значення цільової змінної для кожного об'єкта. Таким чином навчання моделей машинного навчання з учителем полягає у тому, щоб побудувати такий алгоритм, який зможе генералізувати зв'язок між характеристичним описом об'єкта та цільовою змінною.

Фактично, моделі машинного навчання з учителем є дискримінативними, тобто такими, що моделюють умовну ймовірність отримання певного значення цільової змінної, маючи заданий характеристичний опис певного об'єкта, і використовують змодельовану ймовірність у процесі прийняття рішень.

Розглядаючи основні види задач машинного навчання з учителем, насамперед виділяють такі:

- задачі класифікації;
- задачі регресії.

Ключовою відмінністю даних видів задач є тип цільової змінної: у задачах класифікації він скінченний, а в задачах регресії – ні.

Означимо загальне формулювання задачі класифікації – побудова алгоритму, який за характеристичним описанням об'єкта буде моделювати мітку класу, до якого належить даний об'єкт і тим самим розмічати отримані вхідні дані за їх описовими характеристиками.

2.6 Методи оцінки ефективності розпізнавання при класифікації

У задачі класифікації навчальні приклади найкраще розподілити відносно рівномірно між класами, але насправді майже всі набори даних у задачі бінарної класифікації є незбалансованими, що призводить до проблеми якісної оцінки класифікатора. Класична метрика акуратності (accuracy) може дати високе значення,

причому фактично ефект моделі гірший, ніж передбачення, яке завжди визначає один клас.

Для оцінки якості розробленої нейромережі використано метрики оцінки правильності класифікації. Серед них:

- доля вірно знайдених об'єктів;
- точність;
- повнота;
- AUC.

Матриця помилок (confusion matrix) – це таблиця, що часто використовується для ілюстрації якості роботи класифікатора.

Дана матриця фактично є повним описом результатів класифікації, що дозволяє побачити кількість правильно та неправильно класифікованих об'єктів. Досить важливою властивістю такого методу оцінки є те, що багато інших метрик для класифікації виводяться за її допомогою. Матриця зображена на рисунку 2.10.

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

Рисунк 2.10 – Матриця помилок класифікаційної моделі

Дана матриця фактично є повним описом результатів класифікації, що дозволяє побачити кількість правильно та неправильно класифікованих об'єктів. Досить

важливою властивістю такого методу оцінки моделей є те, що багато інших метрик для класифікації виводяться за її допомогою.

«Для оцінки метрик використовуються наступні значення: n_{TP} (True Positive) – число вірно виявлених об'єктів заданого класу, n_{FP} (False Positive) – кількість помилкових спрацьовувань, n_{FN} (False Negative) – кількість невиявлених об'єктів (пропусків)» [10].

Accuracy метрика є найбільш популярною при вирішенні задач класифікації. Це обумовлено простотою розрахунків та інтерпретації результатів роботи. Фактично, ця метрика показує кількість правильних відповідей класифікаційної моделі на певному наборі даних. Серед недоліків слід виділити погану якість роботи на незбалансованих наборах даних.

Precision метрика показує те, як точно модель класифікує об'єкти позитивного класу. Фактично, точність показує величину помилки першого роду, яку робить класифікаційна модель.

Для метрики точності (precision) використовується наступна формула (2.5):

$$precision = \frac{n_{TP}}{n_{TP} + n_{FP}}. \quad (2.5)$$

Повнота (recall, true positive rate) – цей показник ілюструє те, як модель виділяє об'єкти позитивного класу. Низькі значення повноти фактично означають високу помилку другого роду: класифікаційна модель не виділяє об'єкти позитивного класу. Високі значення навпаки, можуть означати те, що у моделі висока помилка першого роду.

Для метрики повноти (recall) використовується наступна формула (2.6):

$$recall = \frac{n_{TP}}{n_{TP} + n_{FN}}. \quad (2.6)$$

Говорячи про точність та повноту, ми розуміємо, що збільшення одного показника часто веде до низьких результатів іншого. F-метрика (score) дозволяє при

оцінці моделей одночасно враховувати як точність, так і повноту. F-метрика – зважене гармонійне середнє між точністю та повнотою.

Одним із способів оцінити модель загалом, не прив'язуючись до конкретного порога, є AUC-ROC (або ROC AUC) – площа (Area Under Curve) під кривою помилок (Receiver Operating Characteristic curve).

ROC (receiver operating characteristic) – дана метрика фактично є кривою, що будується на координатній площині, де за вісь ординат відповідає повнота, а за вісь абсцис – відношення кількості помилкових спрацювань моделі на позитивний клас до кількості об'єктів негативного класу у вибірці. Побудувавши дану криву в одиничному квадраті, розраховують площу під кривою і, фактично, отримують власне значення даної метрики. Цей показник досить часто використовується в задачах класифікації, але його не варто використовувати у випадках нерівномірного розподілу класів у вибірці.

На підставі ROC розраховується показник AUC (Area under the curve), який є загальною площею під кривою залежності вірних та невірних передбачень класифікаційної моделі. Чим ближче до 1 отримані значення, краще система розпізнає класи.

Поставлена у роботі задача диктує і вибір коректної метрики для оцінки моделей класифікації, адже при проведенні медичної діагностики дуже важливо мінімізувати помилку другого роду – тобто кількість випадків, у яких модель «пропускати» позитивний клас, некоректно ідентифікуючи можливе захворювання. Водночас, можливе збільшення помилки першого роду, і, як наслідок, підвищення кількості випадків «хибного спрацювання» моделі є не так важливим, адже набагато гірше не помітити можливий прояв хвороби, аніж помилково здоровому пацієнту вказати на те, що він має деякі прояви того чи іншого захворювання.

2.7 Аналіз існуючих архітектур згорткових мереж для класифікацій зображень

Алгоритми глибоких нейронних мереж сьогодні набули величезної популярності, багато в чому завдяки добре продуманій архітектурі. З моменту свого створення технології штучних нейронних мереж розвивалися досить незалежно від класичних методів, часто радикально змінюючи уявлення про предмет і проблеми теорії машинного навчання та розпізнавання об'єктів. Через деякий час після розробки базових моделей штучних нейронних мереж відбувся великий поділ науки про нейронні мережі на типи топології мережевої архітектури та методи навчання мереж.

2.7.1 Архітектура ResNet

Переможцем ILSVRC 2015 з top – 5 помилкою в 3,57% став ансамбль з шести мереж типу ResNet (Residual Network), розроблений в Microsoft Research. Архітектура ResNet заснована на простій ідеї: обхід вхідних даних для наступного шару відбувається за рахунок спільного використання результату двох попередніх успішних згорткових шарів.

Подібні ідеї виникали і раніше, але в даному випадку автори обходять відразу два шари і використовують цей підхід у великому масштабі. Обхід одного шару не принесе великої користі, а обхід двох — ключове відкриття. Його можна розглядати як невеликий класифікатор або мережу в мережі. Це також був перший приклад навчання мережі, що складається з кількох сотень або навіть тисяч шарів.

Інженери ResNet помітили, що зі збільшенням кількості шарів межа згортальна нейронна мережа може почати деградувати - її точність на тестувальному наборі знижується. Оскільки падає точність і на тренувальному наборі, можна зробити

висновок, що проблема не в перенавчанні мережі.

Було зроблено припущення, що якщо згортальна нейронна мережа досягла своєї межі точності на деякому шарі, то усі наступні шари повинні будуть звиродніти в тотожне перетворення, але із – за складності навчання глибоких мереж цього не відбувається. Для того, щоб "допомогти" мережі, було запропоновано ввести пропускаючі з'єднання (Shortcut Connections), зображені на рисунку 2.11.




Рисунок 2.11 – Пропускаюче з'єднання

Багатошаровий ResNet використовує bottleneck-шар, подібний до того, який використовується в Inception: він зменшує кількість властивостей у кожному шарі, спочатку використовуючи згортку 1×1 із меншим виходом (зазвичай чверть вхідних даних), потім шар 3×3 , а потім знову згортку 1×1 із більшою кількістю властивостей. Як і з модулями Inception, це економить обчислювальні ресурси та зберігає велику кількість комбінацій властивостей. В якості фінального класифікатора в ResNet використовується pooling-шар з softmax.

Тому архітектуру ResNet можна розглядати як систему паралельних і послідовних модулів: у багатьох модулях вхідний/вихідний сигнал є паралельним, а вихідні сигнали кожного модуля з'єднані послідовно.

Оскільки вихідний сигнал циклічний і надається як вхідний, ResNet можна розглядати як покращену надійну модель кори головного мозку.

2.7.2 Архітектура Inception

Творці цієї мережі на чолі з Christian Szegedy виходили з того, що після кожного шару мережі необхідно зробити вибір – чи буде наступний шар сверткой з фільтром 3×3 , 5×5 , 1×1 або ж шаром субдискретизації. Кожен із цих шарів унікальний: фільтр 1×1 виявляє кореляцію між каналами, ширші фільтри реагують на глобальніші ознаки, а шар субдискретизації дозволяє зменшити розмірність без значної втрати інформації.

Ідея полягає в тому, що згортки 1×1 використовуються як модуль зменшення розміру для зменшення bottlenecks, що призводить до збільшення глибини та ширини.

Передумовою для розробки архітектури Inception, архітектура якої зображена на рисунку 2.12, була проблема вибору правильного розміру згортки, придатної як для зображень, де об'єкт може займати дуже мало місця, так і для випадків, коли об'єкт є ключовою фігурою і займає весь простір. Маленькі згортки краще підходять для локально розташованих об'єктів, а більші – для глобально розташованої інформації. Використання великої кількості згорткових шарів значно знижує ефективність обчислень. Також виникла проблема перенавчання моделі, і через збільшення кількості шарів для поглиблення мережі стає неможливим виконати якісне зворотне поширення помилок.

Для вирішення вище зазначених проблем було виконано наступні кроки:

1. Згортки розташовують на одному рівні, щоб розширювати мережу, а не поглиблювати її. Також виконується масимальний пулінг, виходи об'єднуються і передаються на наступний шар.

2. Щоб зменшити обчислювальну складність, згортки 1×1 , які є «дешевшими», додаються перед згортками 5×5 і 3×3 . Така ж згортка додається після max-pulling.




Рисунок 2.12 – Архітектура Inception

Крім того в архітектурі Inception відмовилися від використання повнозв'язного шару у кінці мережі, використовуючи замість нього шар Global Average Pooling (GAP), схема якого зображена на рисунку 2.13, завдяки чому різко зменшилося число параметрів в мережі. Таким чином, Inception, який складається з більш ніж ста шарів, має майже в 12 разів менше параметрів, ніж наприклад AlexNet (близько 7 мільйонів параметрів проти 138 мільйонів).

Раніше використовувалися шари FC, що означає, що на цьому рівні всі входи просто підключалися до кожного вихідного вузла. GAP розглядається як екстремальний тип скорочення, де тензор розмірів $h \times w \times d$ стискається до $1 \times 1 \times d$.




Рисунок 2.13 – Global Average Pooling блок

Варто відзначити, що головною ознакою архітектури Inception є покращене використання обчислювальних ресурсів всередині мережі.

2.7.3 Архітектура MobileNet

MobileNet – це невелика модель з низькою затримкою та малою потужністю, приклади використання зображені на рисунку 2.14, параметризовані для задоволення ресурсних обмежень у різних випадках використання. Вони можуть будуватися для класифікації, виявлення, вбудовування та сегментації, аналогічно тому, як використовуються інші популярні великомасштабні моделі, такі як Inception.




Рисунок 2.14 – Приклади використання архітектури MobileNet

Легка глибока нейронна мережа побудована за допомогою впровадженої концепції глибоко відокремлених згортків. Якщо звичайна згортка поєднує вхідні канали в один піксель, то глибока згортка виконує свою роботу на кожному каналі окремо, що означає, що кожен канал отримує відповідний набір ваг. Фільтруючи канали, ми можемо мати фільтри, такі як кольорові фільтри, але також крайові детектори та інші детектори функцій.

Можемо оцінити пряmlinійність та простоту архітектури зображеної на рисунку 2.15.




Рисунок 2.15 – Архітектура MobileNet

Щодо продуктивності, MobileNet (4 мільйони парам) приблизно в 3 рази швидший за Inception (24 мільйони парам) і в $10 \times$ швидше, ніж VGGNet-16 (138 мільйонів парам). На сучасному смартфоні MobileNet може працювати на 20 FPS з точністю ImageNet 70,6%.

І завдяки цьому Google створив першу архітектуру, яка могла працювати на мобільних пристроях з розумною швидкістю та низькою обчислювальною вартістю, що також вигідно з точки зору споживання акумулятора.

ЗОПИС ПРИЙНЯТИХ ПРОГРАМНИХ РІШЕНЬ

3.1 Обґрунтування вибору платформи та мови програмування

Розробку програмного додатку та алгоритму класифікації було вирішено здійснювати за допомогою мови програмування C# із використанням фреймворку ML.Net.

C# — сучасна об'єктно-орієнтована мова програмування з статичною типізацією. C# дозволяє розробникам створювати різні типи безпечних та надійних програм, що виконуються в .NET.

Розглядаючи функціонал, необхідний для вирішення поставленої задачі, потрібно зазначити і наявність фреймворку для створення, навчання, оцінки та використання моделей – ML.NET.

ML.NET дає вам можливість додавати машинне навчання до додатків .NET у сценаріях онлайн або офлайн. Програми машинного навчання використовують закономірності в даних, щоб робити прогнози, не потребуючи явного програмування.

Центральне місце в ML.NET займає модель машинного навчання. Модель визначає кроки, необхідні для перетворення вхідних даних у прогноз. За допомогою ML.NET можна навчити спеціальну модель, вказавши алгоритм, або імпортувати попередньо навчені моделі TensorFlow і ONNX.

Принцип та етапи побудови моделі для класифікації в ML.NET зображено на рисунку 3.1.




Рисунок 3.1 – Етапи побудови моделі за допомогою ML.NET

Для створення моделі було використано ImageClassificationTrainer, приклад конфігурації зображено на рисунку 3.2, з наступними параметрами:

- кількість тренувальних ітерацій – 100;
- кількість елементів в батчі – 10;
- коефіцієнт швидкості навчання – 0.01;
- коефіцієнт розділу даних на навчальні та тестові – 80:20.

```
var options = new ImageClassificationTrainer.Options()
{
    FeatureColumnName = "Image",
    LabelColumnName = "LabelAsKey",
    Arch = ImageClassificationTrainer.Architecture.MobilenetV2,
    Epoch = 100,
    BatchSize = 10,
    LearningRate = 0.01f,
    MetricsCallback = (metrics) => Console.WriteLine(metrics),
    ValidationSet = testDataView
};
```

Рисунок 3.2 – Приклад конфігурації тренера для побудови моделі

Процес створення моделі машинного навчання складається з наступних етапів:

- фаза калькуляції вузьких місць;
- тренування;
- зберігання, стиснення та архівація готової моделі.

Результат тренування моделі для класифікації МРТ зображень зображено на рисунку 3.3.

```
*****
*   Metrics for TensorFlow DNN Transfer Learning multi-class classification model
*   -----
    AccuracyMacro = 0.9805, a value between 0 and 1, the closer to 1, the better
    AccuracyMicro = 0.9807, a value between 0 and 1, the closer to 1, the better
    LogLoss = 0.0466, the closer to 0, the better
    LogLoss for class 1 = 0.0353, the closer to 0, the better
    LogLoss for class 2 = 0.0583, the closer to 0, the better
*****
```

Рисунок 3.3 – Метрики отримані після навчання моделі

Так як програмний продукт передбачає інтерактивну відповідь на вхідні данні в мережі інтернет, тому важливим фактором при виборі мови програмування є можливість швидкого та зручного розміщення моделі в серверному з відкрити API.

C# є мовою програмування, що зокрема використовується для написання бекенд (backend) частини багатьох програмних продуктів, а отже є чудовим кандидатом для створення веб-додатку.

Тож, ураховуючи усі ці особливості, було вирішено використовувати саме дану мову програмування.

Розглядаючи фреймворки, необхідні для якісної реалізації веб-сервісу, що буде використовувати побудований алгоритм машинного навчання для вирішення практичної задачі, то C# надає найкращий з можливих варіантів – ASP.Net Core.

ASP.NET Core є кросплатформовим, високопродуктивним середовищем з відкритим вихідним кодом для створення сучасних хмарних програм, підключених до Інтернету. Даний фреймворк є дуже корисним при розробці продуктів, які повинні отримувати деякі вхідні дані, розрахувати на їх основі відповідні показники та віддавати результат користувачу.

Отже, ураховуючи усі особливості розглянутих засобів, у роботі було вирішено використовувати ASP.NET Core, як найбільш відповідний варіант.

3.2 Опис інтерфейсу користувача для застосування розробленого методу

Для зручного використання розробленого методу класифікації та покращення досвіду користувача (UX) при роботі з методом був розроблений SPA додаток за допомогою фреймворку Angular та мови програмування TypeScript. Даний додаток є посередником між користувачем та сервером на якому розміщена класифікаційна модель.

Під час взаємодії з додатком користувач обирає папку з зображеннями для класифікації. Потім додаток відправляє всі зображення, що знаходяться в обраній папці, до класифікаційного серверу в паралельному режимі. Приклад результату класифікації, який відображається в вигляді відповіді класифікаційного серверу зображено на рисунку 3.4.



	Назва: no1480.jpg Прогнозований значення: no Ймовірність: 0.99999785 Час виконання прогнозу: 83
	Назва: no1489.jpg Прогнозований значення: no Ймовірність: 0.98388255 Час виконання прогнозу: 80
	Назва: y1481.jpg Прогнозований значення: yes Ймовірність: 0.99999976 Час виконання прогнозу: 68
	Назва: y1480.jpg Прогнозований значення: yes Ймовірність: 1 Час виконання прогнозу: 64

Рисунок 3.4 – Приклад виводу результату класифікації

Для виконання класифікації сервер отримує файл зображення, яке необхідно класифікувати, та повертає відповідь в JSON форматі з наступними параметрами:

- прогнозоване значення – yes або no;
- ймовірність – число значення від 0 до 1 з точність до 7 знаків;
- час виконання прогнозу в мілісекундах.

3.3 Архітектура згорткової нейронної мережі MobilenetV2 для класифікації МРТ зображень

Метою роботи є розробка економічного в плані пам'яті методу класифікації пухлин головного мозку на МРТ знімках з високим рівнем точності. Таким чином, обрано стандартну модель згорткової нейронної мережі на базі архітектури MobilenetV2, яка містить 28 шарів.

Структура MobileNetV2 побудована на згортках, які можна розділити по глибині за винятком першого рівня, який є повною згорткою. Усі рівні супроводжуються batchnorm і нелінійністю ReLU, за винятком останнього повнозв'язного шару, який не має нелінійності та подається на рівень softmax для класифікації. На рисунку 3.5 порівнюється шар із регулярними згортками, batchnorm і ReLU нелінійністю до факторизованого шару з поглибленою згорткою, згорткою 1×1 , а також batchnorm і ReLU після кожного згорткового шару. Архітектура MobileNetV2 зображена на рисунку 3.6.




Рисунок 3.5 – Порівняння шарів стандартної архітектури (зліва) та MobileNetV2 (праворуч)

Зменшення вибірки обробляється за допомогою поступової згортки в згортках по глибині, а також у першому шарі. Остаточне усереднене об'єднання зменшує

просторову роздільну здатність до 1 перед повнозв'язним шаром. Розраховуючи глибинні та точкові згортки як окремі шари, MobileNetV2 має 28 шарів.

Table 1. MobileNet Body Architecture		
Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5×	Conv dw / s1 $3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
	Conv / s1 $1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
	Conv dw / s2 $3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
	Conv / s1 $1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
	Conv dw / s2 $3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
	Conv / s1 $1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
	Avg Pool / s1 Pool 7×7	$7 \times 7 \times 1024$
	FC / s1 1024×1000	$1 \times 1 \times 1024$
	Softmax / s1 Classifier	$1 \times 1 \times 1000$

Рисунок 3.6 – Архітектура нейронної мережі

Структура моделі MobileNetV2, зображена на рисунку 3.7, поміщає майже всі обчислення в щільну згортку 1×1 . Це можна реалізувати за допомогою високо оптимізованих функцій множення загальної матриці (GEMM). Часто згортки реалізуються за допомогою GEMM, але вимагають початкового впорядкування в пам'яті під назвою `im2col`, щоб зіставити його з GEMM. Згортки 1×1 не потребують такого впорядкування в пам'яті та можуть бути реалізовані безпосередньо за допомогою GEMM, який є одним із найбільш оптимізованих алгоритмів числової лінійної алгебри.




Рисунок 3.7 – Візуалізація шарів в MobileNetV2

Важливість лінійних bottlenecks. Лінійні моделі bottlenecks є строго менш потужними, ніж моделі з нелінійністю, оскільки активації завжди можуть працювати в лінійному режимі з відповідними змінами у зміщеннях і масштабуванні. Однак експерименти, показані рисунку 3.8, показують, що лінійні вузькі місця покращують продуктивність, забезпечуючи підтвердження того, що нелінійність знищує інформацію в низьковимірному просторі.




Рисунок 3.8 - Вплив нелінійності на bottleneck шар

MobileNetV2 витрачає 95% свого обчислювального часу на згортки 1×1 , які також мають 75% параметрів, як можна побачити в таблиці 3.1. Майже всі додаткові параметри знаходяться на повнозв'язним шарі.

Таблиця 3.1 – Ресурси на кожен тип шару

Тип	Mult-Adds	Параметри
Згортка 1×1	94.86%	74.59%
Згортка DW 3×3	3.06%	1.06%
Згортка 3×3	1.19%	0.02%
Повнозв'язний шар	0.18%	24.33%

Модель MobileNetV2 була навчена в TensorFlow за допомогою RMSprop з асинхронним градієнтним спуском, подібним до Inception V3. Однак, на відміну від методів навчання великих моделей, для MobileNetV2 використовується менше методів регуляризації та розширення даних, оскільки маленькі моделі мають менше проблем із перенавчанням. Під час навчання MobileNetV2 не використовується згладжувальні мітки та додатково зменшено кількість спотворень зображення, обмежуючи розмір малих кадрів, які використовуються у початковому навчанні.

Для класифікації використовувались MPT зображення головного мозку, отримані з відкритого джерела – Br35H: Brain Tumor Detection 2020 [11].

В даному датасеті зображення розділені на дві групи: yes та no по 1500 MPT зображень у кожній. Кожен файл представляє собою MPT знімок головного мозку в поздовжньому положенні.

3.4 Навчання моделі MobileNetV2

Модель навчалась з використанням наступних параметрів:

- кількість тренувальних ітерацій – 100;
- кількість елементів в батчі – 10;
- коефіцієнт швидкості навчання – 0.01;
- коефіцієнт розділу даних на навчальні та тестові – 80:20.




Рисунок 3.9 – Результати навчання мережі з архітектурою MobileNetV2

Як видно з графіків, високі значення (вище 0.9) метрик було отримано вже після десятої епохи, що свідчить про високу навчальну здатність такої архітектури нейромережі.

3.5 Аналіз отриманих результатів

Продуктивність розробленого методу класифікації порівняно з іншими найновішими методами комп'ютерного зору для класифікації медичних зображень. В таблиці 3.2 наведено порівняння продуктивності цих методів.

Найменшу точність у 86% показує класифікатор Random Forest. За винятком D-CNN, точність, досягнута системами на основі CNN, становить від 91% до 96%. Лише D-CNN досяг 98,07% точності, що все ще нижче точності, яку показує метод, розроблений в даній роботі. Серед цих дев'яти методів шість базуються на CNN, але жодна з них не працює краще, ніж метод, запропонована та розроблений в даній роботі. Модель CNN з архітектурою MobileNetV2 перевершила всі інші запропоновані методи класифікації.

Таблиця 3.2 – Порівняння методів класифікації зображень

Назва або посилання	Технологія	Навчальні зображення	Зображення для тестування	Точність
[12]	Random Forest Classifier	372	193	86%
[13]	CNN	2450	615	91.3%
[14]	R-CNN	2450	600	91.66%
ResNet	ANN	1600	400	92.14%
[15]	Support Vector Machine (SVM)	1572	930	97.1%
AlexNet [16]	Deep CNN (D-CNN)	1372	493	97.8%
MobileNetV2	CNN	1600	400	98.07%

ВИСНОВКИ

У результаті кваліфікаційної роботи була розроблений згорткова нейронна мережа для бінарної класифікації МРТ-зображень головного мозку.

Уся розробка виконувалася в середовищі Microsoft Visual Studio 2022 для розробки моделі та серверної частини та Visual Studio Code для клієнтської частини. Компоненти програмного продукту розроблені з використанням мови програмування С#, фреймворку .NET 6, ML.NET технології Web Api для серверної частини та мовою програмування TypeScript і фреймворком Angular для клієнтської частини.

У результаті було розроблено нейронна мережа для класифікації медичних МРТ зображень, яка дозволяє медичним спеціалістам діагностувати рак головного мозку по МРТ зображенням з точністю 98.07%. Це дозволяє медичним фахівцям оптимізувати процес діагностики, отримувати результати діагностування за досить короткий проміжок часу та з великою точністю.

Попри виконання поставленої задачі, в роботі ще є напрями для подальшого вдосконалення. Перш за все, напрямками для майбутнього розвитку є: робота з зображеннями низької якості, зменшення часу на виконання класифікації, а також підвищення точності результатів.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Brain Tumor Classification (MRI), Abstract. / Kaggle – URL: <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri> (дата звернення: 21.09.2022 р).
2. Cancer / World Health Organization – URL: <https://www.who.int/news-room/fact-sheets/detail/cancer> (дата звернення: 22.09.2022 р).
3. DiMasi J. A., Hansen R. H. G. The Price of Innovation: New Estimates of Drug Development Costs. J Health Econ. – 2003. – Vol. 22, No. 2. – P. 151–185.
4. Магнітно-резонансна томографія / Лікувально-діагностичний центр – URL: <https://ldc.dn.ua/uk/mrt/1354-mahnitno-rezonansna-tomohrafiia-mrt-mri> (дата звернення: 24.09.2022 р).
5. Момоток Л. О. Основи медичної інформатики / Л. О. Момоток, Л. В. Юшина, О. О. Рожнова. – К: Підручник, 2008. – С. 166–168.
6. Абрамов Н. С. Современные интеллектуальной обработки данных ДЗЗ / Н.С. Абрамов, Д.А. Макаров, А.А. Талалаев, В.П. Фраленко // Программные системы: теория и приложения. – 2018. – Т.9. – № 4(39). – С. 417–442.
7. Гонсалес Р.С, Вудс Р.П. Цифровая обработка изображений – М.: Техносфера. – 2006. – 1072 с.
8. Білінський Й.Й. Обробка та використання мультиспектральних зображень Й.Й. Білінський, Б.П. Книш, Я.А. Кулик // Наукові праці ВНТУ. – 2020.
9. Statistical Analysis of K-Nearest Neighbor Collaborative Recommendation URL: <https://arxiv.org/pdf/1010.0499.pdf> (дата звернення: 05.10.2022).
10. Ерохин Д. Ю., Ершов М. Д. Современные сверточные нейронные сети для обнаружения и распознавания объектов // Цифровая обработка сигналов. – 2018. – №. 3. – С. 64.

11. Br35H :: Brain Tumor Detection 2020 / Kaggle – URL: <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection> (дата звернення: 24.11.2022 p).
12. M. Soltaninejad, G. Yang, T. Lambrou, “Supervised learning based multimodal MRI brain tumour segmentation using texture features from supervoxels,” // Computer Methods and Programs in Biomedicine. – 2018. C. 69–84.
13. S. Sarkar, A. Kumar, S. Chakraborty, S. Aich, J. S. Sim, and H. C. Kim, “A CNN based approach for the detection of brain tumor using MRI scans,” // Test Engineering and Management. – 2020. C. 16580–16586.
14. E. Avşar and K. Salçin, “Detection and classification of brain tumours from MRI images using faster R-CNN” // Tehnički glasnik – 2019. T.13. – №4. – C. 337–342.
15. J. Amin, M. Sharif, M. Yasmin, and S. L. Fernandes, “A distinctive approach in brain tumor detection and classification using MRI” // Pattern Recognition Letters – 2017. – C. 139.
16. Sangdoo Y. CutMix: Regularization Strategy to Train Strong Classifiers with Localizable Features, 2011 – p. 13–20.