

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ ЕКОНОМІЧНИЙ УНІВЕРСИТЕТ ІМЕНІ
ВАДИМА ГЕТЬМАНА

Навчально-науковий інститут «Інститут інформаційних технологій в економіці»

Кафедра системного аналізу та кібербезпеки

ОСВІТНЬО-ПРОФЕСІЙНА ПРОГРАМА

«Системний аналіз»

СПЕЦІАЛЬНІСТЬ

124 «Системний аналіз»

Форма навчання: _____ денна

КВАЛІФІКАЦІЙНА МАГІСТЕРСЬКА РОБОТА

На тему: «Медична діагностика критичних захворювань на основі штучного інтелекту»

Здобувача: Голочка Володимира Володимировича

(підпис)

Науковий керівник: д.ф.-м.н., проф. Пічкур Володимир Володимирович

(підпис)

Робота допущена до захисту перед екзаменаційною комісією з атестації здобувачів вищої освіти (ЕК)

Завідувач кафедри: д.ф.-м.н., проф. Джалладова І.А.

(підпис)

Київ 2025

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ ЕКОНОМІЧНИЙ УНІВЕРСИТЕТ ІМЕНІ
ВАДИМА ГЕТЬМАНА

Навчально-науковий інститут «Інститут інформаційних технологій в економіці»

Кафедра системного аналізу та кібербезпеки

ОСВІТНЬО-ПРОФЕСІЙНА ПРОГРАМА

«Системний аналіз»

СПЕЦІАЛЬНІСТЬ

124 «Системний аналіз»

ПОГОДЖЕНО

Керівник проєктної групи (гарант)
освітньо-професійної програми

ЗАТВЕРДЖУЮ

Завідувач кафедри системного аналізу
та кібербезпеки

Колечкіна Л.М.

(підпис)

Джалладова І.А.

(підпис)

2025 р.

2025 р.

ІНДИВІДУАЛЬНЕ ЗАВДАННЯ

здобувачу вищої освіти

Толочку Володимиру Володимировичу

денної форми навчання

на підготовку кваліфікаційної магістерської роботи

На тему: «Медична діагностика критичних захворювань на основі штучного інтелекту»

Тему затверджено наказом ректора Університету від «___» _____ 2025р. №___

Кваліфікаційна магістерська робота виконується на матеріалах

План кваліфікаційної магістерської роботи

Розділ 1

Сучасні методи виявлення пухлин та їх глобальний контекст.

Розділ 2	Теоретичні основи глибокого навчання та архітектури згорткових нейронних мереж.
Розділ 3	Практична реалізація системи діагностики на основі CNN.
Об'єкт дослідження:	Процес медичної діагностики із використанням методів штучного інтелекту.
Предмет дослідження:	Предметом дослідження є моделі глибокого навчання для виявлення пухлин головного мозку на основі МРТ-зображень.
Мета кваліфікаційної магістерської роботи:	Метою кваліфікаційної магістерської дипломної роботи є підвищення точності та ефективності діагностики пухлин головного мозку шляхом розроблення системи класифікації МРТ-зображень на основі згорткових нейронних мереж.

Конкретні завдання, які здобувач повинен виконати для досягнення поставленої мети:

У розділі 1

1. Ознайомитись з сучасними підходами до використання штучного інтелекту у медичній діагностиці.
2. Проаналізувати існуючі методи діагностики пухлин головного мозку.
3. Розглянути особливості застосування глибокого навчання у задачах обробки медичних зображень.

У розділі 2

1. Розглянути архітектури згорткових нейронних мереж та їх переваги у медичному застосуванні.
2. Вивчити методи попередньої обробки даних, нормалізації, аугментації та використання механізмів callbacks.
3. Сформулювати підхід до вибору оптимальної моделі на основі метрик точності, повноти, F1-міри та валідаційних результатів.

У розділі 3

1. Реалізувати процес класифікації МРТ-знімків мозку з використанням згорткових нейронних мереж у середовищі Google Colab.
2. Провести навчання моделей, візуалізацію втрат, точності, побудову матриць плутанини та аналіз результатів.

3. Розробити рекомендації щодо впровадження моделі в медичну практику та визначити напрями її подальшого вдосконалення.

**Завдання підготував
науковий керівник**

(підпис)

Пічкур В. В.

(ініціали, прізвище)

«__» _____ 2025 р.

**Завдання одержав
здобувач**

(підпис)

Толочко В.В.

(ініціали, прізвище)

«__» _____ 2025 р.

Реферат

Кваліфікаційна магістерська робота містить 70 сторінок; 4 таблиці; 31 рисунок; список літератури з 52 найменувань.

«Медична діагностика критичних захворювань на основі штучного інтелекту»

Об'єкт дослідження – процеси медичної діагностики пухлин головного мозку.

Предмет дослідження – методи та моделі глибокого навчання, зокрема згорткові нейронні мережі (CNN), що використовуються для автоматизованої обробки МРТ-зображень мозку з метою виявлення пухлин.

Мета кваліфікаційної магістерської роботи – розробка та дослідження системи автоматизованої діагностики пухлин головного мозку на основі нейромережевих моделей для підвищення ефективності медичної діагностики в умовах обмежених ресурсів.

Відповідно до поставленої мети були поставлені та вирішені такі завдання:

- провести аналіз сучасних методів виявлення пухлин головного мозку та визначити їхні переваги й обмеження;
- дослідити принципи функціонування згорткових нейронних мереж та можливості їх використання в задачах класифікації медичних зображень;
- реалізувати та навчити архітектури CNN (VGG16, InceptionV3, MobileNetV2) на реальних МРТ-даних;
- здійснити порівняльну оцінку точності моделей за допомогою метрик (точність, повнота, F1-міра, матриця плутанини);
- обґрунтувати доцільність використання попередньо навчених моделей у контексті країн, що розвиваються;

Теоретична значущість кваліфікаційної магістерської роботи полягає в систематизації знань про застосування методів глибокого навчання у медичній сфері, зокрема для задач виявлення пухлин мозку, та в поглибленні розуміння архітектур CNN як інструменту аналізу візуальних медичних даних.

Методична значущість полягає у розробці поетапного підходу до побудови та тестування моделей машинного навчання, який охоплює підготовку даних, їх обробку, вибір оптимальної моделі та її адаптацію до специфіки медичних знімків.

Практичне значення отриманих результатів роботи полягає у створенні ефективної системи автоматизованого виявлення пухлин головного мозку, яка може бути інтегрована у системи медичних рішень, особливо у регіонах з обмеженим доступом до висококваліфікованих фахівців та сучасного обладнання.

Рік виконання кваліфікаційної магістерської роботи 2025

Рік захисту роботи 2025

Ключові слова: штучний інтелект, медична діагностика, глибоке навчання, згорткові нейронні мережі, МРТ-зображення, CNN, класифікація пухлин.

Відгук
на кваліфікаційну магістерську роботу
навчально-наукового інституту інформаційних технологій в економіці освітньо-
професійної програми «Системний аналіз»

Толочка Володимира Володимировича
(прізвище, ініціали)

на тему Медична діагностика критичних захворювань на основі штучного інтелекту
(назва теми)

Актуальність теми кваліфікаційної магістерської роботи обґрунтовується тим, що на сучасному етапі у галузі охорони здоров'я стрімко зростає рівень використання інтелектуальних систем. В задачах автоматизованої діагностики захворювань постає проблема підвищення ефективності застосування систем штучного інтелекту і інформаційних технологій.

Розвиток і впровадження таких технологій дозволить здійснювати діагностику критичних захворювань в умовах відсутності сучасного обладнання та за обмежень на кваліфікацію медичних працівників. В магістерській роботі Толочком В.В. здійснено аналіз теоретичних основ використання штучного інтелекту в медичній діагностиці.

Визначено особливості застосування згорткових нейронних мереж для класифікації МРТ-знімків головного мозку. Проведено структурований порівняльний аналіз точності, стабільності та продуктивності трьох архітектур - VGG16, InceptionV3 і MobileNetV2. У розділі 3 роботи представлено практичну реалізацію моделей штучного інтелекту, підготовку медичних даних, візуалізацію результатів навчання та оцінку якості моделей. Результати дослідження можуть бути застосовані для розробки і впровадження діагностичних ШІ-систем у медичних установах, зокрема в тих установах з обмеженими матеріальними і людськими ресурсами. Запропоновані підходи відповідають сучасним тенденціям у сфері медичних ІТ-рішень і мають прикладне значення. В роботі відсутні недоліки, які впливають на високу позитивну оцінку роботи.

Вважаю, що кваліфікаційна магістерська робота Толочка Володимира Володимировича на тему “Медична діагностика критичних захворювань на основі штучного інтелекту” є самостійною роботою, відповідає всім вимогам, що ставляться до кваліфікаційних магістерських робіт, робота може бути допущена до захисту, а автор цієї роботи, Толочко Володимир Володимирович, заслуговує на оцінку “відмінно” та на присвоєння освітньо-кваліфікаційного рівня “магістр”.

(посада, учене звання, науковий ступінь)

Пічкур В.В.

(прізвище, ініціали)

(підпис)

“ _____ ” 2025 р.

РЕЦЕНЗІЯ

на кваліфікаційну магістерську роботу
здобувача вищої освіти
Толочка Володимира Володимировича

Тема «Медична діагностика критичних захворювань на основі штучного інтелекту/ **Medical diagnostics of critical diseases based on artificial intelligence**»

Тема кваліфікаційної магістерської роботи Толочка Володимира Володимировича є актуальною, оскільки вона пов'язана зі створенням систем обробки інформації, які використовують сучасні досягнення в області штучного інтелекту і можуть бути застосовані в галузі охорони здоров'я. Прикладна проблема, якої торкається робота, полягає у тому, щоб, використовуючи технологію штучного інтелекту, створити методики діагностики захворювань, які б можна було використовувати в складних умовах відсутності якісного медичного обладнання та за обмежень на фінансування медичної галузі. В магістерській роботі автор проводить аналіз наукових джерел, які стосуються теми дослідження. Для задачі класифікації МРТ-знімків головного мозку він показує, якими є особливості застосування згорткових нейронних мереж. Здійснюється порівняльний аналіз точності, стабільності та продуктивності трьох архітектур - VGG16, InceptionV3 і MobileNetV2.

У роботі представлено практичну реалізацію моделей штучного інтелекту, підготовку медичних даних, візуалізацію результатів навчання та оцінку якості моделей. Здобувач демонструє володіння теоретичними знаннями з галузі штучного інтелекту та навички практичного програмування у середовищі Google Colab із застосуванням TensorFlow та Keras. Робота написана грамотною українською мовою, оформлена у відповідності до встановлених вимог. Матеріал роботи подано логічно і структуровано, а висновки роботи обгрунтовані. Наявні зауваження і недоліки роботи не впливають на позитивну оцінку роботи.

Результати магістерського дослідження можуть бути використані при розробці систем автоматизованої діагностики на основі медичних зображень. Запропоновані архітектурні рішення мають прикладне значення і можуть бути застосовані для реалізації діагностичних інструментів у клінічній практиці, а також у мобільних застосунках, орієнтованих на країни з обмеженим доступом до високоспеціалізованої медичної допомоги.

Грунтуючись на аналізі роботи, можна зробити висновок, що кваліфікаційна магістерська робота Толочка Володимира Володимировича на тему «Медична діагностика критичних захворювань на основі штучного інтелекту» відповідає всім вимогам до кваліфікаційних магістерських робіт і її автор заслуговує на оцінку «відмінно».

Місце роботи та посада рецензента
завідувач кафедри моделювання складних систем
факультету комп'ютерних наук та кібернетики
Київського національного університету
імені Тараса Шевченка,
доктор технічних наук, доцент

Черній Д.І.

Підпис засвідчую:

(посада, підпис)

Місце печатки організації, де працює рецензент

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	3
ВСТУП	4
РОЗДІЛ 1. СУЧАСНІ МЕТОДИ ВИЯВЛЕННЯ ПУХЛИН ТА ЇХ ГЛОБАЛЬНИЙ КОНТЕКСТ	9
1.1 Розроблені програми застосування ШІ в медицині	9
1.2 Аналіз сучасних методик виявлення пухлин головного мозку.....	10
1.3 Масштаб дослідження і цілі.....	13
1.4 Комп'ютерне бачення та нейронні мережі.....	15
РОЗДІЛ 2. ТЕОРЕТИЧНІ ОСНОВИ ГЛИБОКОГО НАВЧАННЯ ТА АРХІТЕКТУРИ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ	19
2.1 Згорткові нейронні мережі: принцип роботи та структура.....	19
2.2 Представлення CNN та приклади архітектур.....	21
2.3 Методи попереднього навчання та передумови для ефективної класифікації	23
РОЗДІЛ 3. ПРАКТИЧНА РЕАЛІЗАЦІЯ СИСТЕМИ ДІАГНОСТИКИ НА ОСНОВІ CNN	30
3.1 Характеристика датасету та аналіз розподілу класів	30
3.2 Попередня обробка даних	33
3.3 Зворотні виклики та контрольні точки	34
3.4 Метрики для оцінювання задачі класифікації	35
3.5 Реалізація моделей VGG16, InceptionV3 та MobileNetV2.....	38
3.5 Оцінка результатів: метрики точності, f1 рахунок, матриця плутанини	49
3.6 Порівняльний аналіз моделей та вибір найефективнішої.....	59
3.7 Подальші напрями удосконалення запропонованого методу	62
ВИСНОВКИ	64
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	65

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

AI - Artificial Intelligence - Штучний інтелект (ШІ).

CNN – Convolutional Neural Network – Згортова нейронна мережа.

MPT - Magnetic resonance imaging - Магнітно-Резонансна Томографія.

КТ - Computed tomography - Комп'ютерна Томографія.

ПЕТ - Positron emission tomography - Позитронно-Емісійна Томографія.

фМРТ - functional magnetic resonance imaging - Функціональна Магнітно-резонансна Томографія.

ДТТ - Diffusion tensor imaging - Дифузійно-Тензорна Томографія.

MPC - Magnetic resonance spectroscopy - Магнітно-Резонансна Спектроскопія.

ReLU - Rectified Linear Activation - Прямолінійна активація з ректифікацією.

ЦНС - Central nervous system - Центральна Нервова Система.

ШНМ - Artificial neural network - Штучна Нейронна Мережа.

КБ - Computer vision - Комп'ютерне Бачення.

ВСТУП

Пухлини головного мозку є одними з найстрашніших медичних діагнозів, що впливають на широкий демографічний спектр - від дітей до дорослих. У Сполучених Штатах щорічно діагностують приблизно 25 400 злоякісних пухлин головного і спинного мозку, при цьому рівень захворюваності на ці пухлини центральної нервової системи (ЦНС) становить 14 420 серед чоловіків і 10 980 серед жінок[33]. Рівень смертності, пов'язаний з цими раковими утвореннями, становить приблизно 18 760 смертей, що очікується за той самий період часу. Показники виживання пацієнтів з діагнозом «пухлина головного мозку» значно різняться залежно від декількох факторів, включаючи тип пухлини, вік на момент встановлення діагнозу і, нарешті, доступність методів лікування. Для первинних пухлин головного мозку приблизна 5-річна виживаність становить близько 36%, що підкреслює агресивну природу цих злоякісних новоутворень[34]. Ці ураження ЦНС зазвичай класифікують на гліобластоми, астроцити, олігодендрогліоми та інші.

Всебічне розуміння цих пухлин, з їх різноманітними розмірами та локалізацією в мозку, вимагає досвіду нейрохірургів, який зазвичай оцінюється за допомогою МРТ-обстеження. Шлях до нейрохірургічної експертизи є трудомістким і фінансово затратним, він займає від 14 до 16 років цілеспрямованого навчання, починаючи з бакалаврату і закінчуючи резидентурою. Цей довгий освітній шлях призводить до нестачі нейрохірургів, особливо в країнах з меншою фінансовою гнучкістю та можливостями[35].

Цей дефіцит означає, що багато людей, які страждають від пухлин головного мозку, не мають доступу до сучасної діагностики та лікування, і ця проблема ускладнюється високим рівнем травм голови, які потенційно можуть спровокувати ріст пухлини головного мозку.

Актуальність роботи полягає в тому, що наразі не існує гнучкої системи, яка б дозволяла швидко і точно виявляти пухлини головного мозку на МРТ-зображеннях, яку можна було б легко перенавчати. Щоб заповнити цю прогалину, це дослідження пропонує розробку такої системи. Очікується, що ця система буде використовувати складні нейронні мережі, такі як Inception-v3, і використовувати платформи, такі як Kaggle, для навчання і перевірки моделі з винятковою точністю обробки даних.

Метою дослідження є створення системи виявлення пухлин головного мозку на основі МРТ для підвищення ефективності та точності діагностики. Швидка ідентифікація пухлин за допомогою такої системи може суттєво вплинути на розробку ефективних планів лікування.

Для досягнення цієї мети необхідно вирішити такі **завдання**:

- Провести аналіз сучасних підходів до автоматизованої діагностики медичних зображень, зокрема методів виявлення пухлин головного мозку;
- дослідити принципи функціонування згорткових нейронних мереж (CNN) та їхню придатність для задач класифікації МРТ-знімків;
- підібрати та реалізувати архітектури глибокого навчання (VGG16, MobileNetV2, InceptionV3) для виявлення пухлинних утворень;
- провести навчання моделей і здійснити їхню порівняльну оцінку за критеріями точності, повноти, F1-міри та ефективності;
- визначити переваги та обмеження кожної з моделей з огляду на можливість використання в умовах обмежених ресурсів, зокрема в країнах, що розвиваються;

Дослідження буде зосереджено на класифікації пухлин головного мозку в системах охорони здоров'я нерозвинених країн та країн, що розвиваються.

Це дослідження має на меті зрозуміти, як ці передові методи можуть бути адаптовані та впроваджені в середовищах з різним рівнем якості даних та технологій медичної візуалізації. Використовуючи зворотні виклики для

динамічного коригування в процесі навчання моделі, включаючи зміну швидкості навчання, контрольні точки моделі та дострокову зупинку, це дослідження фокусується на оптимізації продуктивності моделі та забезпеченні перенесення найефективніших вагових коефіцієнтів моделі для подальшого застосування на різноманітних наборах даних.

Такий підхід підкреслює потенціал рішень машинного навчання, які можуть зробити значний внесок у розвиток охорони здоров'я, особливо в регіонах з обмеженими ресурсами, що підкреслює важливість адаптивних і стійких технологій у глобальному контексті охорони здоров'я.

У цьому дослідженні оцінюється адаптивність попередньо навчених моделей згорткових нейронних мереж (CNN) для класифікації пухлин головного мозку, зосереджуючи увагу на їхній ефективності при застосуванні до специфічних і часто складних умов, що зустрічаються в країнах, які розвиваються. Це передбачає поступове перенавчання моделі CNN, спочатку навченої на різноманітних даних з різних фонів, з використанням менших, більш репрезентативних наборів даних, які зазвичай зустрічаються в країнах, що розвиваються, де якість МРТ-сканування та маркування даних може бути недостатньо узгодженою. Основна увага приділяється багаторазовому використанню та перенесенню отриманих вагових коефіцієнтів моделі, що є потенційним рішенням для подолання потреби у великих анотованих наборах даних у регіонах з обмеженими ресурсами та можливостями.

Отримані результати підкреслюють критичну роль збережених вагових коефіцієнтів моделі у покращенні узагальнюваності моделі та мінімізації обчислювальних витрат. Це особливо актуально в умовах, коли ефективність та адаптивність відіграють важливу роль у перенавчанні моделі. Крім того, в дослідженні обговорюється критична роль цього методу у створенні справедливого діагностичного інструменту, заснованого на даних, який може орієнтуватися на обмеження, що стосуються інфраструктури охорони здоров'я.

Теоретична значущість даного дослідження полягає в систематизації знань щодо використання методів глибокого навчання у задачах медичної діагностики, зокрема виявлення пухлин головного мозку на основі МРТ-зображень. У роботі узагальнено ключові підходи до побудови згорткових нейронних мереж, описано особливості їх архітектур та принципів функціонування. Розгляд моделей VGG16, MobileNetV2 та InceptionV3 дозволяє поглибити розуміння того, як сучасні алгоритми комп'ютерного зору можуть бути адаптовані до специфіки медичних задач. Окрім цього, дослідження сприяє подальшому розвитку теоретичних основ штучного інтелекту в сфері медичних застосувань, зокрема щодо інтерпретації, обробки та аналізу візуальної інформації за допомогою нейронних мереж.

Методична значущість дослідження полягає в розробці цілісного підходу до побудови, навчання та оцінювання моделей глибокого навчання для задач виявлення пухлин головного мозку. У роботі покроково викладено процес підготовки медичного зображувального датасету, його попередньої обробки, застосування one-hot кодування, а також масштабування вхідних даних. Окрему увагу приділено налаштуванню архітектур нейронних мереж, реалізації алгоритмів навчання з використанням бібліотек TensorFlow і Keras, а також методам валідації результатів із залученням метрик точності, повноти, F1-міри та побудови матриць неточностей. Запропонований методичний підхід може бути використаний як основа для створення навчальних кейсів, курсів із машинного навчання, або практичних семінарів з комп'ютерного зору в медицині.

Практична значущість дослідження полягає у створенні та тестуванні ефективної моделі автоматизованого виявлення пухлин головного мозку на основі методів глибокого навчання. Запропоновані підходи можуть бути інтегровані в системи підтримки медичних рішень, що використовуються у закладах охорони здоров'я для покращення якості діагностики. Особливо цінним є те, що обрані моделі (зокрема MobileNetV2) характеризуються високою точністю при низьких обчислювальних витратах, що відкриває можливість їх застосування на мобільних

пристроях або в умовах обмежених технічних ресурсів. Такий підхід є надзвичайно актуальним для клінік у країнах, що розвиваються, де доступ до висококваліфікованих спеціалістів обмежений, а потреба в ефективних і доступних діагностичних інструментах є критичною.

Інформаційну базу дослідження становлять відкриті медичні датасети МРТ-знімків головного мозку з класифікацією типів пухлин, доступні на платформі Kaggle, а також наукові публікації, документація до бібліотек TensorFlow і Keras, і результати експериментального моделювання в середовищі Google Colab.

Отже, це дослідження виступає за стратегічне впровадження функцій зворотного зв'язку в моделях CNN. Воно передбачає модель передачі знань, коли знання, отримані в більш придатних умовах, перепрофільовуються для покращення результатів лікування в менш привілейованих регіонах. Цей підхід підкреслює більш широку прихильність до просування глобальної справедливості в галузі охорони здоров'я шляхом демократизації доступу до технологій штучного інтелекту в медичній сфері.

Структура роботи складається з чотирьох розділів:

- Перший розділ присвячено аналізу проблеми виявлення пухлин головного мозку, ознайомленню читача з існуючими методологіями та постановці задачі.;
- другий розділ містить огляд математичних основ, важливих для нейронних мереж, і розглядає різні архітектури для подальшої реалізації;
- третій розділ оцінює отримані результати моделей за допомогою узгоджених методів і метрик;
- у висновках підводяться підсумки дослідження, піднімаються етичні аспекти проекту та пропонуються подальші кроки для його вдосконалення.

РОЗДІЛ 1

СУЧАСНІ МЕТОДИ ВИЯВЛЕННЯ ПУХЛИН ТА ЇХ ГЛОБАЛЬНИЙ КОНТЕКСТ

1.1 Розроблені програми застосування ШІ в медицині

В останні роки багато систем охорони здоров'я та лікарів почали інтегрувати нейронні мережі в свої діагностичні процеси[36].

Наприклад:

- Загальна лікарня штату Массачусетс: Ця установа тісно пов'язана з Гарвардською медичною школою, вона використовує нейронні мережі для аналізу медичних зображень, включаючи технології МРТ і мамографії, для діагностики та ідентифікації захворювань.

- Каліфорнійський університет у Сан-Франциско: у цьому випадку нейронні мережі використовуються для аналізу електронних медичних записів і прогнозування результатів лікування різних захворювань, таких як сепсис і відмова органів.

- Клініка Майо: відома своєю комплексною системою охорони здоров'я і використовує нейронні мережі для аналізу медичних зображень і даних про пацієнтів, щоб визначити ймовірність прогресування захворювання і поліпшити результати лікування.

- Медичний центр Стенфордського університету: у Стенфорді розробляють алгоритми нейронних мереж, які здатні ідентифікувати пацієнтів з високим ризиком таких захворювань, як сепсис, які можуть бути небезпечними для життя і важко діагностуються.

- Клівлендська клініка: ця клініка робить акцент на підвищенні точності та ефективності аналізу медичних зображень, особливо в радіології та патології.

Ці приклади свідчать про зростаючу тенденцію використання нейронних мереж для різних медичних застосувань, що свідчить про те, що все більше медичних установ визнають потенціал ШІ в підтримці діагностичних процесів і результатів лікування. Розвиток технологій штучного інтелекту продовжується, і прогнозується, що в найближчі роки все більше медичних організацій впроваджуватимуть нейронні мережі у свою діяльність для допомоги в діагностиці пацієнтів і підвищення загальної якості медичної допомоги.

Впровадження нейронних мереж для розпізнавання пухлин головного мозку є як значною можливістю, так і викликом. Хоча наведені приклади зосереджені на установах з потужною фінансовою та технологічною інфраструктурою, існує потенціал для адаптації цих методів на основі штучного інтелекту в умовах обмежених ресурсів. Ця адаптація може бути посилена завдяки партнерству і співпраці з великими установами, моделям ШІ з відкритим вихідним кодом і міжнародному обміну знаннями. Це може сприяти подоланню бар'єрів доступності та постійному вдосконаленню процесу прийняття рішень щодо медичних діагнозів у цих регіонах.

Основною метою цього дослідження та впровадження системи розпізнавання пухлин головного мозку є подальше підвищення точності діагнозів, оптимізація процесу лікування і, зрештою, покращення показників виживаності та тривалості життя пацієнтів. Оскільки технології штучного інтелекту і нейронних мереж стають все більш доступними, існує чіткий напрямок для їх застосування, що сприятиме демократизації передової медичної допомоги в усьому світі.

1.2 Аналіз сучасних методик виявлення пухлин головного мозку

В академічних дослідженнях, спрямованих на покращення виявлення пухлин головного мозку, кілька передових методів візуалізації були визначені як ключові. У цій частині звіту представлено огляд сучасних діагностичних

методологій з точки зору їх адаптивності та актуальності для країн, що розвиваються, та країн з низьким рівнем розвитку[37].

Магнітно-резонансна томографія (МРТ)

Основним методом діагностики пухлин головного мозку є магнітно-резонансна томографія (МРТ), яка використовує магнітні поля для отримання зображень структур головного мозку з високою роздільною здатністю. Її використання є важливим для правильної діагностики та планування лікування, оскільки вона точно визначає розташування, розмір і тип пухлини. Але апарати МРТ вимагають спеціалізованої інфраструктури та навченого персоналу, що обмежує доступність в умовах обмежених ресурсів.

Комп'ютерна томографія (КТ)

Комп'ютерна томографія (КТ) пропонує швидшу та більш широкодоступну альтернативу, використовуючи рентгенівські промені для створення детальних анатомічних зображень головного мозку. Хоча вона забезпечує швидші результати, особливо важливі в екстрених випадках, КТ-візуалізація забезпечує нижчу роздільну здатність порівняно з МРТ та передбачає вплив іонізуючого випромінювання, що робить повторне використання менш бажаним.

Позитронно-емісійна томографія (ПЕТ)

Відстежуючи радіоактивно мічені речовини, що поглинаються активними клітинами, позитронно-емісійна томографія (ПЕТ) дає уявлення про метаболізм пухлини. Це дозволяє виділити злоякісні та доброякісні новоутворення. Незважаючи на свої переваги у виявленні метаболічної активності, ПЕТ є дорогим методом і вимагає доступу до радіоактивних трасерів і сучасного обладнання, якого часто бракує в слаборозвинених районах.

Функціональна МРТ (фМРТ)

Функціональна МРТ (фМРТ) додає можливості функціонального картування, виявляючи зміни кровотоку, пов'язані з активністю мозку. Вона допомагає нейрохірургам зберігати життєво важливі функції під час планування

хірургічного втручання. Однак фМРТ вимагає не лише дорогого обладнання, але й складної інтерпретації, що обмежує її використання за межами передових медичних центрів.

Дифузійно-тензорна томографія (ДТТ)

Дифузійно-тензорна томографія (ДТТ), розширення МРТ, відстежує дифузію молекул води для виявлення ділянок білої речовини, допомагаючи оцінити інфільтрацію пухлини в тканини мозку. Її висока чутливість є очевидною перевагою, але її складність та вимога до спеціалізованих інструментів обробки створюють значні перешкоди в менш розвинених регіонах.

Магнітно-резонансна спектроскопія (МРС)

Магнітно-резонансна спектроскопія (МРС) доповнює МРТ, аналізуючи хімічний склад тканин, пропонуючи метаболічні дані, які можуть розрізнити типи та ступені пухлини. Хоча МРС є цінною, вона є технічно вимогливою та досі недостатньо використовується через обмежену доступність та труднощі з інтерпретацією.

На відміну від цих усталених, але ресурсомістких методів, у моїй роботі пропонується впровадження штучного інтелекту та нейронних мереж як альтернативного підходу до виявлення пухлин головного мозку. Системи ШІ, навчені на достатній кількості даних візуалізації, можуть автоматизувати ідентифікацію та класифікацію пухлин з високою точністю.

Переваги ШІ включають нижчі експлуатаційні витрати, потенціал для використання на портативних або хмарних платформах та масштабованість навіть в умовах обмеженої медичної інфраструктури. Ці системи можуть розширити охоплення діагностики в сільській та слаборозвинених районах, де доступ до сучасного обладнання для візуалізації та спеціалістів обмежений.

Однак їхня ефективність залежить від якості та кількості навчальних даних, і вони можуть зіткнутися з проблемами клінічної валідації, схвалення регуляторними органами та інтеграції в існуючі системи охорони здоров'я.

Підсумовуючи, хоча традиційні методи візуалізації залишаються високоефективними та точними, вони часто недоступні або недоступні за ціною в середовищах з обмеженими ресурсами. Штучний інтелект пропонує перспективну, економічно ефективну альтернативу, яка може демократизувати діагностику пухлин головного мозку в усьому світі, особливо за умови підтримки спільного обміну даними, постійного навчання моделей та інтеграції з ініціативами телемедицини.

У цьому розділі підкреслюється критична роль глобальних зусиль у сфері охорони здоров'я, спрямованих на подолання технологічного розриву, забезпечення рівного доступу до діагностичних можливостей для пацієнтів з пухлинами головного мозку, незалежно від географічних та економічних бар'єрів. Завдяки такому підходу можна значно покращити прогноз при пухлинах головного мозку, що вплине на стан охорони здоров'я в економічно слабкорозвинених регіонах.

1.3 Масштаб дослідження і цілі

Проект зосереджений на розробці нейромережевої системи класифікації пухлин головного мозку, створеної для застосування в нерозвинених країнах та країнах, що розвиваються. Ця система надає пріоритет бінарній ідентифікації між наявністю або відсутністю пухлини, з «відсутністю пухлини» як однією з ключових класифікацій, перед визначенням типу пухлини, якщо вона присутня.

Основною метою є досягнення високої точності класифікації категорії «немає пухлини» з особливим акцентом на оптимізацію точності для уникнення хибнопозитивних результатів, що мінімізує непотрібне лікування і стрес для пацієнтів. Високий відсоток впізнаваності також є критично важливим для того, щоб не пропустити жодного випадку пухлини, особливо на етапі виявлення. Показник F1, у свою чергу, важливий для збалансування показників точності та відтворення, щоб система була одночасно чутливою та специфічною.

Для підвищення гнучкості та адаптивності моделей, особливо при роботі з новими та небаченими даними, процес розробки включає реалізацію зворотних

викликів та контрольних точок. Зворотні виклики використовуються під час навчання для моніторингу продуктивності моделі, застосування коригувань, таких як зменшення швидкості навчання або дострокова зупинка, коли прогрес вирівнюється, таким чином запобігаючи надмірному пристосуванню. Контрольні точки зберігають модель на різних етапах, гарантуючи, що найефективніша версія зберігається і може бути перезавантажена для подальшого навчання або оцінювання.

Очікується, що завдяки впровадженню цих стратегій надана система відповідатиме суворим медичним стандартам, необхідним для використання в медицині, і залишатиметься надійною та ефективною в динамічних умовах, характерних для обмежених ресурсів. Цей підхід спрямований на підвищення ефективності діагностики і потенційну інтеграцію передових технологій ШІ в місцеву практику охорони здоров'я, що в кінцевому підсумку покращить результати лікування завдяки ефективному і точному визначенню наявності або відсутності пухлин.

Підсумовуючи, можна сказати, що штучний інтелект (ШІ) і нейронні мережі відіграли і продовжують відігравати вирішальну роль у сучасній медицині, як це було детально описано в попередніх розділах цього дослідження. У цій дискусії було належним чином досліджено вирішальний вплив цих технологій на медичну сферу, зокрема їхню інтеграцію в клінічну практику та їхній потенціал революціонізувати надання медичної допомоги та діагностику.

Крім того, мною надано всебічний аналіз патології пухлин головного мозку з вивченням статистики захворюваності, сучасних методів виявлення та притаманних пухлинам характеристик. Обговорення також окреслило поточну актуальність і майбутній потенціал застосування штучного інтелекту в медичних програмах, підкресливши системну постановку дослідницького завдання.

Наданий набір даних слугуватиме основною засадою для послідовності процедур, які будуть детально описані далі. Підготовка набору даних, що є важливим кроком для будь-якого дослідження, заснованого на даних, була ретельно

задокументована для забезпечення чіткості та відтворюваності в майбутніх дослідженнях.

1.4 Комп'ютерне бачення та нейронні мережі

Комп'ютерне бачення (КБ) - це галузь штучного інтелекту (ШІ), що займається навчанням комп'ютерів інтерпретувати та розуміти візуальні дані зі світу. Ця підгалузь ШІ набула популярності, оскільки методи глибокого навчання, особливо ті, що знаходяться в авангарді цієї галузі - їх часто називають сучасними (SOTA) моделями - демонструють виняткову продуктивність на еталонних наборах даних. Практичне застосування комп'ютерного зору різноманітне: від автономних транспортних засобів і систем моніторингу втоми в автомобільній промисловості до інтелектуальних рішень для паркування.

Воно також поширюється на сектор охорони здоров'я, включаючи застосування в ядерній медицині для точного таргетування в променевої терапії. Крім охорони здоров'я та автомобілебудування, технології КБ підвищують операційну ефективність у різних галузях, наприклад, використання розпізнавання символів у процесах сортування пошти.

У галузі комп'ютерного бачення використовуються дані, отримані за допомогою камер і датчиків, і ці дані допомагають у виконанні безлічі завдань, включаючи оцінку глибини, яка обчислює відстань об'єктів від об'єктива камери[2], як показано на рисунку 1.1.



Рисунок 1.1 – Процес оцінки глибини

Джерело: [2]

Процес інтерпретації та розуміння візуальних даних за допомогою комп'ютерного зору ґрунтується на нейронних мережах. Ці складні моделі, навчаючись розпізнавати закономірності у візуальних даних, роблять різноманітні застосування комп'ютерного зору настільки ж ефективними і точними, наскільки вони є.

Нейронні мережі, в свою чергу, є підмножиною моделей машинного навчання, натхненних структурою і функціями людського мозку. Вони складаються з взаємопов'язаних вузлів, або нейронів, організованих пошарово. Кожен нейрон обробляє вхідні дані, виконує обчислення і передає сигнали. Ці сигнали, відомі як ваги, мають вирішальне значення для здатності мережі навчатися і приймати рішення.

Процес навчання нейронної мережі передбачає коригування вагових коефіцієнтів, щоб мережа могла розпізнавати закономірності та робити точні прогнози або класифікації. Цей процес навчання складається з декількох етапів:

- Підготовка даних: Набір даних, що містить приклади вхідних даних і відповідних правильних результатів, готується для навчання і перевірки.

- Ініціалізація: Ваги мережі ініціалізуються, часто невеликими випадковими значеннями, щоб розпочати процес навчання. Випадкова ініціалізація допомагає уникнути проблем симетрії і дозволяє різним нейронам навчатися різним функціям.

- Пряме поширення: Протягом кожної епохи навчання дані проходять через мережу, і для кожного шару обчислюється вихідний результат.

- Поширення у зворотному напрямку: Вихідні помилки мережі використовуються для коригування ваг у напрямку, протилежному градієнту помилки.

- Оптимізація функції втрат: Мережа використовує алгоритми оптимізації, такі як градієнтний спуск, для мінімізації помилки.

- Оновлення ваг: Ваги оновлюються на основі градієнта похибки. Правило оновлення зазвичай коригує ваги в напрямку, протилежному градієнту помилки, щоб знайти оптимальні ваги.

- Ітерації: Процеси прямого і зворотного розповсюдження повторюються через декілька ітерацій або епох.

- Верифікація: Після кожної ітерації продуктивність мережі перевіряється за допомогою валідаційного набору даних.

Навчання завершується, коли мережа досягає адекватного рівня точності на валідаційних даних. Після цього навчену нейронну мережу можна використовувати для прогнозування нових, ще не бачених даних. Використання нейронних мереж дає системі численні переваги:

- Адаптивність: Нейронні мережі можуть самостійно навчатися і адаптуватися до нових даних.

- Видобування інформації: Вони чудово виділяють закономірності та особливості з величезних обсягів даних.

- Стійкість до шуму: Нейронні мережі, як правило, стійкі до зашумлених даних.

- Відмовостійкість: Вони можуть зберігати функціональність, навіть коли деякі дані або компоненти мережі виходять з ладу.

Застосування нейронних мереж є широко розповсюдженим, що дозволяє швидко вирішувати складні завдання і дозволяє моделям представляти нюанси поведінки в складних структурах.

Нейронні мережі відомі своєю універсальністю в обробці різних типів даних. Ця універсальність робить їх потужним інструментом для вирішення цілого ряду складних інтелектуальних завдань. Їх часто порівнюють зі здатністю людського мозку до навчання та розпізнавання закономірностей, що доводить їхню ефективність у вирішенні різноманітних складних інтелектуальних завдань.

РОЗДІЛ 2

ТЕОРЕТИЧНІ ОСНОВИ ГЛИБОКОГО НАВЧАННЯ ТА АРХІТЕКТУРИ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ

2.1 Згорткові нейронні мережі: принцип роботи та структура

Згорткові нейронні мережі (CNN)[5] - це унікальний клас глибоких штучних нейронних мереж прямого поширення, які особливо добре підходять для обробки даних з відомою сіткоподібною топологією, таких як зображення. ШНМ були розроблені для розпізнавання візуальних патернів безпосередньо з піксельних зображень з мінімальною попередньою обробкою, обробляючи такі варіації зображення, як спотворення, зсуви та зміни з високим ступенем інваріантності.

Людський мозок обробляє величезну кількість візуальної інформації щосекунди, і кожен нейрон у певній області, відомій як рецептивне поле, обробляє різні сегменти зорового поля. Подібним чином, згорткові нейронні мережі мають нейрони, які реагують на ділянки зорового поля, що перекриваються, - концепція, натхненна біологічним процесом.

Згорткові нейромережі зазвичай складаються з трьох типів шарів: згорткового шару, шару об'єднання (субдискретизації) і повністю з'єднаного шару, як показано на схемах, що додаються на рисунку 2.1.




Рисунок 2.1 – Архітектура згорткової нейронної мережі

Джерело: [6]

Пояснення шарів згорткових нейромереж

1. Згортковий шар: Базовий шар складається зі згорткового шару, який відіграє вирішальну роль на етапі виявлення особливостей при обробці зображення. Він застосовує до вхідного зображення набір фільтрів, що навчаються, які допомагають виявити прості об'єкти, такі як краї та кути. Кожен фільтр просторово невеликий, але поширюється на всю глибину вхідного об'єму. Коли фільтр ковзає (або згортається) навколо вхідного зображення, створюється двовимірна карта активації цього фільтра, яка надає мережі просторову інформацію.

2. Об'єднуючий шар: Після шару згортки йде шар об'єднання, який виконує певну форму нелінійної низхідної дискретизації. У шарі об'єднання є кілька функцій, таких як max об'єднання, що допомагає мережі стати інваріантною до малих перетворень вхідних даних. Цей шар зменшує просторові розміри (ширину і висоту) вхідного об'єму для наступного згорткового шару, зменшуючи кількість параметрів і обчислювальне навантаження на мережу, а отже, також допомагає контролювати перенавчання.

3. Повністю зв'язаний шар: Останній шар - це повністю зв'язаний шар, який бере високорівневі відфільтровані зображення з попередніх шарів і переводить їх у голоси, використовуючи функцію активації softmax у задачах класифікації. По суті, робота цього шару полягає в тому, щоб призначити ймовірності для кожної мітки класу над вхідними даними на основі ознак, розпізнаних у попередніх шарах.

Функціонування ШНМ

Фільтри згорткового шару застосовуються до вхідних даних за допомогою механізму ковзного вікна для виявлення ознак. На етапі об'єднання мережа бере максимальне значення (у випадку максимального об'єднання) з карти ознак у вікні, коли вона ковзає по зображенню, ефективно зменшуючи розмірність карти ознак, зберігаючи при цьому найсуттєвішу інформацію. Цей процес проілюстровано на

рисунок, що додаються, де показано операції, які виконуються над матричними представленнями зображень.

Згорткові нейронні мережі використовують різні принципи розпізнавання образів і машинного навчання для інтерпретації сенсорних даних. Завдяки шарам нейронів, які імітують процес візуального сприйняття, CNN можуть класифікувати вхідні дані, такі як зображення, з високою точністю, що робить їх особливо корисний у таких галузях, як розпізнавання зображень і відео, класифікація зображень, аналіз медичних зображень та багато інших.

2.2 Представлення CNN та приклади архітектур

Як приклад, ImageNetV2 є оновленим варіантом відомого набору даних ImageNet[10], призначеним для оцінки узагальнюючої здатності глибоких згорткових нейронних мереж. Цей набір було розроблено задля надання більш збалансованої альтернативи оригінальному ImageNet[10] (особливо його валідаційному піднабору), і він використовується переважно для перевірки продуктивності попередньо навчених моделей на нових, але подібних до оригінальних прикладах. Відповідно, ImageNetV2 не є архітектурою моделі, як LeNet-5, а радше тестовим набором, однак його часто використовують у зв'язку з сучасними моделями, такими як EfficientNet або Vision Transformers.

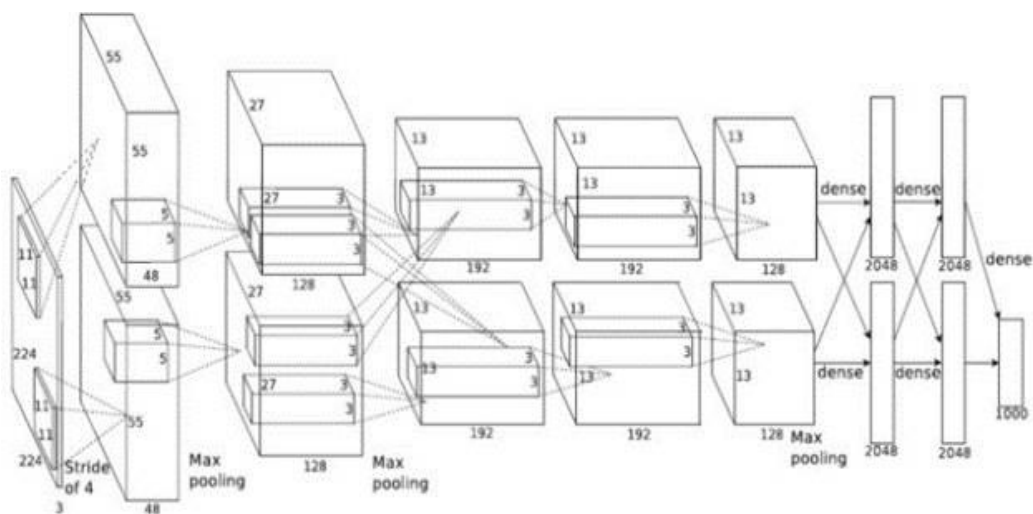


Рисунок 2.2 – Приклад згортки

Джерело: [17]

Для обробки зображень з набору ImageNetV2 часто використовуються моделі глибоких згорткових мереж із оптимізованою структурою, розроблені для мобільних та обмежених обчислювальних пристроїв. Однією з таких моделей є MobileNetV2 — ефективна архітектура, що поєднує швидкодію, компактність та високу точність. Вона складається з початкового згорткового шару, серії інверсних резидульних блоків (inverted residual blocks) із вузькими "ботлнек"-шарми, та фінального шару класифікації.

Початковий згортковий шар у MobileNetV2 має ядро 3×3 з кроком 2, яке формує карту ознак зменшеного розміру. За ним слідує серія інверсних залишкових блоків, кожен із яких включає розширювальний шар (1×1), згортку (3×3) та стискувальний шар (1×1). Головною особливістю таких блоків є збереження залишкових з'єднань не між виходами згортки, як у ResNet, а між їх вузькими "вхідними" векторами — звідси і назва інверсні.

Передостанній шар — глобальне середнє об'єднання (global average pooling), що агрегує просторову інформацію з усіх карт ознак. Кінцевий повністю зв'язаний шар з 1000 нейронами (для ImageNetV2) і функцією активації Softmax генерує ймовірності приналежності зображення до кожного з класів.

Загальна кількість параметрів у MobileNetV2 становить приблизно 3,4 мільйона, що суттєво менше, ніж у ResNet-50 (близько 25 мільйонів). Незважаючи на компактність, MobileNetV2 демонструє конкурентоспроможні результати на задачах класифікації, що робить її надзвичайно привабливою для застосування в реальних умовах, зокрема в мобільних пристроях або в умовах обмежених ресурсів.

Таким чином, ImageNetV2 у поєднанні з архітектурою MobileNetV2 забезпечує ефективну платформу для оцінки здатності моделей до узагальнення, особливо в тих випадках, коли важлива балансованість між точністю, швидкістю обчислень та кількістю параметрів.

J. Сітха та С. Селвакумар Раджа у своєму дослідженні «Класифікація пухлин головного мозку з використанням згорткових нейронних мереж» [38] досліджують застосування методів глибокого навчання, зокрема, згорткових нейронних мереж, для класифікації пухлин головного мозку на наданих МРТ-зображеннях. Згідно з роботою, основною проблемою в цій галузі є різноманітність форм пухлин головного мозку та місць, де вони виникають. Це ускладнює процеси ручної класифікації через величезні обсяги даних, що генеруються під час МРТ-сканування.

У роботі окреслено критичну роль лікування пухлин головного мозку, які бінарно поділяються на доброякісні та злоякісні. Обговорюються традиційні методи візуалізації, такі як КТ та УЗД, однак МРТ підкреслюється завдяки своїй чудовій деталізації структури мозку та виявленню аномалій.

2.3 Методи попереднього навчання та передумови для ефективної класифікації

У дослідженні використовуються CNN завдяки їхній здатності автоматизувати процеси вилучення та класифікації ознак. Це допомагає зменшити потребу в ручному втручанні, яке часто обмежує можливості обробки великих наборів даних. Автори розробили глибоку архітектуру з невеликими ядрами для ефективної обробки детальних нюансів даних медичної візуалізації, досягнувши заявленої точності 97,5%.

Методологія запропонованої класифікації пухлин головного мозку показана на рисунку 2.3. Цей рисунок ілюструє детальну структуру і робочий процес використовуваної моделі згорткової нейромережі, виділяючи різні шари і процеси, задіяні в класифікації.



Рисунок 2.3 – Основні аспекти фаз навчання і тестування CNN

Джерело: побудовано автором

Запропонована модель CNN особливо відзначається своєю низькою складністю та високою точністю. Дослідження окреслює переваги глибокого навчання в аналізі медичних зображень без обширної попередньої обробки, якої вимагають інші методи. На рисунку 2.4 показані результати класифікації, які є наочним доказом того, що модель точно класифікує зображення мозку на категорії пухлин і непухлинних утворень.




Рисунок 2.4 – Результати класифікації за допомогою CNN

Джерело: побудовано автором на основі [11]

Крім того, на рисунку 2.5 детально показано точність класифікації пухлин головного мозку, що демонструє вищу продуктивність моделі CNN порівняно з іншими методами.

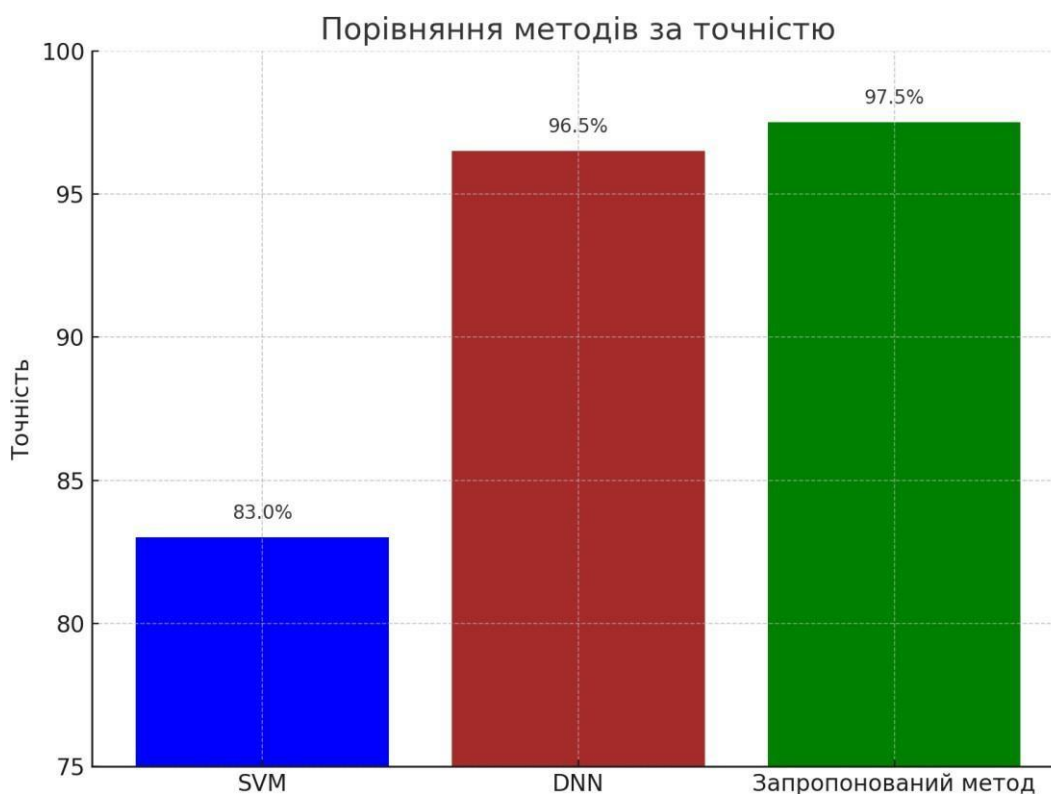


Рисунок 2.5 – Точність результатів класифікації за допомогою CNN

Джерело: побудовано автором

З іншого боку, наукова стаття «Підхід до машинного навчання для класифікації пухлин головного мозку за допомогою МРТ» Равікумара Гурусамі та доктора Віджаяна Субраманіама[38] покращує процес діагностики пухлин головного мозку за допомогою МРТ-сканування за допомогою складних методів аналізу даних. Дослідження фокусується на інтеграції зменшення шуму, сегментації, виділення ознак та класифікації. Згідно з дослідженням, це значно покращує чіткість, точність та ефективність діагностики пухлин головного мозку.

Починаючи з зменшення шуму, дослідження використовує вейвлет-перетворення, які, як показано, перевершують традиційні фільтри, такі як гаусові або медіанні фільтри, у збереженні деталей зображення при мінімізації шуму. У статті зазначено, що таке покращення якості зображення є критично важливим для точного виявлення об'єктів. Рисунок 2.6 ілюструє ефективність методів, що використовуються для покращення чіткості зображення.




Рисунок 2.6 – Ефективність методів сегментації

Джерело: побудовано автором на основі [11]

На етапі сегментації використовуються автоматизовані методи, щоб відрізнити пухлинні тканини від нормальних тканин мозку, що зазвичай робиться радіологами вручну. Ця автоматизація зменшує варіабельність діагностики та покращує відтворюваність результатів.

Виділення ознак використовує вейвлет-перетворення для вилучення детальної просторової та частотної інформації з очищених і сегментованих зображень. Ці ознаки є критично важливими для етапу класифікації. Процес виділення ознак, який описує кроки, пов'язані з виділенням і редукцією ознак, представлений на рисунку 2.7.



Рисунок 2.7 – Процес вилучення сегментованої інформації з очищених зображень

Джерело: побудовано автором на основі [26]

Нарешті, у дослідженні описується етап класифікації, забезпечуючи ефективність різних моделей машинного навчання, включаючи бінарні опорні вектори. Показники ефективності, такі як позитивна прогностична цінність та негативна прогностична цінність для різних класифікаторів, включаючи нейронну мережу, KNN, наївний Байєс та запропонований SVM, детально показані на рисунку 2.8.

	Класифікатор	Позитивна прогностична цінність	Негативна прогностична цінність
0	Нейронна мережа	97.0	97.0
1	KNN	96.0	96.0
2	Наївний Байєс	89.21	93.7
3	Запропонований SVM	98.0	98.0

Рисунок 2.8 – Порівняння показників ефективності моделей машинного навчання

Джерело: побудовано авторами на основі [2]

Ця таблиця підкреслює ефективність SVM, яка має найвищі показники серед представлених моделей.

Пухлини головного мозку існують у різних формах, кожна з яких має свої унікальні патологічні ознаки. Тип пухлини головного мозку визначається типом клітин, з яких вона походить. Спеціалізовані лабораторні дослідження можуть дати уявлення про тип задіяних клітин. Не всі типи пухлин головного мозку є злоякісними. Вони можуть бути класифіковані як неракові (доброякісні) або ракові (злоякісні).

Доброякісні пухлини головного мозку, такі як менінгіоми, які зазвичай з'являються в оболонках, що покривають головний і спинний мозок, іноді можуть трансформуватися в злоякісні форми. Менінгіоми є найпоширенішим доброякісним типом. Гліоми, з іншого боку, включаючи астроцити, олігодендрогліоми та епендиміоми, походять з гліальних клітин і мають ризик стати злоякісними, де гліобластома є найпоширенішим злоякісним типом гліоми.

Існує також класифікація, відома як гіпофізарні пухлини, які виникають у гіпофізі. Часто доброякісні, вони можуть суттєво впливати на гормональний баланс і призводити до значних проблем зі здоров'ям через своє розташування біля основи мозку.

РОЗДІЛ 3

ПРАКТИЧНА РЕАЛІЗАЦІЯ СИСТЕМИ ДІАГНОСТИКИ НА ОСНОВІ CNN

3.1 Характеристика датасету та аналіз розподілу класів

База даних, яка була використана для цього дослідження, містить загалом 3264 МРТ-зображення, які були розподілені на

- 926 випадків гліоми,
- 937 випадків менінгіоми,
- 500 випадків «без пухлини»,
- 901 зображення пухлин гіпофіза головного мозку.

Графічне зображення розподілу даних представлено на рисунку 3.1.

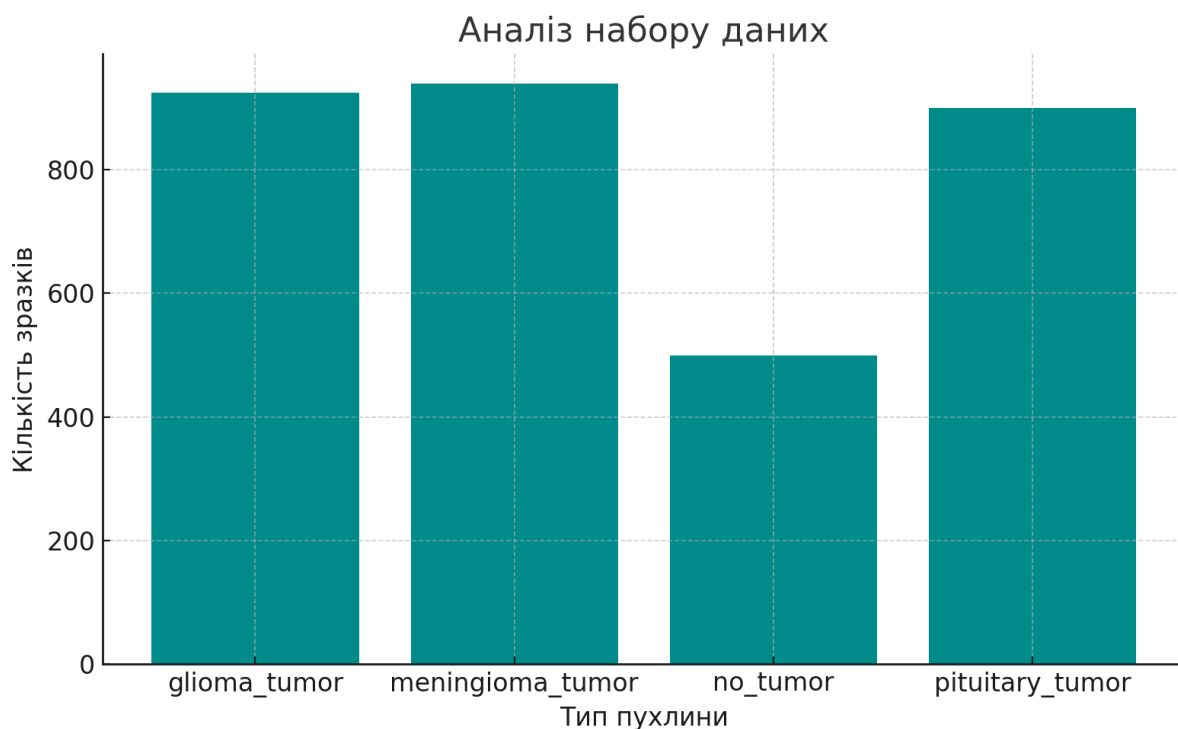


Рисунок 3.1 – Розподіл набору даних за типом пухлини

Джерело: побудовано автором на основі [11]




Рисунок 3.2 – Приклад знімку з пухлиною менінгома

Джерело: побудовано авторами на основі [11]




Рисунок 3.3 – Приклад знімку без пухлини

Джерело: побудовано авторами на основі [11]

Кожне зображення має свій розмір. Тому для процесу навчання моделі класифікації пухлин головного мозку необхідно стандартизувати МРТ-зображення до єдиного розміру. Крім того, значення пікселів на кожному зображенні, які знаходяться в діапазоні від 0 до 255, повинні бути нормалізовані. Ця нормалізація має вирішальне значення для забезпечення того, щоб вхідні дані для навчання моделей знаходилися в масштабі, з яким моделі можуть ефективно працювати.

Дані будуть розділені на окремі набори для навчання і тестування. У процесі навчання буде використано кілька складних архітектур нейронних мереж. Після навчання модель, яка продемонструє найвищу точність, буде обрана для використання на тестовому наборі. Цей крок спрямований на створення автоматизованої системи, яка зможе ідентифікувати пухлини на МРТ-зображеннях завдяки своїм точним прогностичним можливостям.

Створення автоматизованих методів класифікації з використанням машинного навчання та штучного інтелекту постійно доводить вищу точність порівняно з ручною класифікацією. Тому запропонована система, яка включає класифікацію за допомогою алгоритмів глибокого навчання та використання нейронних мереж, стане цінним інструментом для лікарів у всьому світі.

Такий підхід підкреслює важливість використання передових обчислювальних методів для підвищення точності та ефективності медичних діагнозів, зокрема, при виявленні пухлин головного мозку за допомогою МРТ-сканування. Інтеграція такої технології може стати значним поштовхом для світових постачальників медичних послуг, пропонуючи надійний і надійний інструмент у діагностичному процесі.

3.2 Попередня обробка даних

Набір даних у цьому випадку складається з МРТ-зображень мозку. Ці зображення різняться за розміром, але для ефективного навчання моделі їх потрібно привести до єдиного розміру, наприклад, (224, 224, 3). Нормалізація гарантує, що значення пікселів, які вважаються ознаками в задачах класифікації зображень, стандартизовані. Процес включає приведення значень пікселів до масштабу від 0 до 255. Зокрема, він передбачає перетворення значень пікселів до діапазону, де максимальне значення нормалізується до найвищого можливого значення шкали, зазвичай 255.

1. **Пакетна нормалізація:** Це метод, який стандартизує вхідні дані для мережі, допомагаючи стабілізувати і прискорити процес навчання. Застосування масштабного коефіцієнта, як правило, допомагає активаційним функціям мережі виводити більш значущі градієнти і покращує алгоритм оптимізації градієнтного спуску для оновлення параметрів моделі.

2. **Доповнення даних:** Метою доповнення даних є урізноманітнення набору даних без фактичного збору нових даних. Це передбачає створення варіацій існуючих даних, які можуть включати поворот зображень або зміну їхнього масштабу. Це робить модель більш стійкою до різних видів варіацій, з якими вона може зіткнутися в нових, небачених даних.

3. **Масштабування ознак:** Нормалізація даних допомагає в точному налаштуванні дрібних деталей. Коли нейронні мережі навчаються, використовуючи зображення трьох різних розмірів для отримання інформації, вони можуть надавати непропорційно велике значення певним ознакам, що може ввести в оману процес навчання. Тому значення пікселів часто зменшують з діапазону від 0 до 255 до нового де максимальне значення пікселя дорівнює 1, щоб переконатися, що всі вхідні ознаки однаково впливають на процес навчання.

Ці кроки мають вирішальне значення для підготовки даних для моделі машинного навчання, особливо в задачах класифікації зображень, щоб гарантувати, що модель ефективно навчається і добре узагальнює нові дані.

Google Colab використовувався як середовище розробки, а Google Drive - як сховище файлів. Набір даних, використаний для дослідження, доступний на онлайн-платформі Kaggle[11].

3.3 Зворотні виклики та контрольні точки

Моделі машинного навчання часто вимагають значних обчислювальних ресурсів і часу для навчання, що робить ефективний моніторинг і державне управління критично важливими, особливо в умовах обмежень нерозвинених країн і країн, що розвиваються. Зворотній зв'язок у машинному навчанні - це функції, які викликаються на певних етапах процесу навчання, що дозволяє відстежувати, коригувати та втручатися в режимі реального часу. Контрольні точки[12], в той же час, є спорідненою концепцією, де стан моделі зберігається через певні проміжки часу або за певних умов, керуючи відновленням і поновленням без початку з нуля.

Зворотні виклики[12] можуть бути використані для покращення процесу перенавчання шляхом динамічного налаштування параметрів навчання у відповідь на продуктивність на нових наборах даних. Аналогічно, зворотні виклики можуть реалізовувати функцію ранньої зупинки, щоб запобігти надмірному пристосуванню до непередбачуваних даних, перериваючи процес навчання, як тільки продуктивність моделі на валідаційному наборі перестає покращуватися. Це може суттєво вплинути на розподіл ресурсів, мінімізуючи обчислювальні ресурси та запобігаючи погіршенню узагальнюваності моделі.

Контрольні точки забезпечують основу, на якій модель можна швидко та ефективно перенавчати, зберігаючи стан моделі в певних точках під час початкового етапу навчання. Це особливо корисно, коли новий набір даних відносно невеликий або коли обчислювальні ресурси обмежені, оскільки це

дозволяє застосовувати стратегії інкрементного навчання або навчання з перенесенням. Модель можна перезавантажити з контрольної точки, а потім перенавчити або доопрацювати на невидимих даних, що значно скорочує час і ресурси, необхідні для адаптації моделі до нових завдань або оновлених наборів даних.

Таким чином, зворотні виклики та контрольні точки надають зручні інструменти для динамічного та ефективного перенавчання моделей машинного навчання на нових наборах даних, керуючи адаптивністю та стійкістю моделі, особливо в умовах обмежених ресурсів. Такий підхід допомагає подолати розрив між мінливими ландшафтами даних і постійною потребою в актуальних і точних моделях машинного навчання.

3.4 Метрики для оцінювання задачі класифікації

У цьому пункті розглядаються показники, які важливі для оцінки виконання завдань машинного навчання. Використовуючи такі метрики, ми можемо зменшити надмірне пристосування моделі, гарантуючи, що вона добре працює на нових, раніше не бачених даних. Матриця плутанини[34] описується як інструмент візуалізації, який ілюструє точність моделі в задачах класифікації, розділяючи результати на чотири категорії на основі фактичних і прогнозованих значень. Матриця об'єднує прогнози і факти в таблицю, яка зображена на рисунку 3.4.

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

Рисунок 3.4 – Приклад матриці плутанини

Джерело: [24]

Значення TP, FP, FN та TN в контексті Матриці плутанини:

1. TP (True Positive) означає, що модель передбачила позитивний клас, і фактичний результат також є позитивним.
2. TN (True Negative) означає, що модель передбачила негативний клас, і фактичний результат є негативним.
3. FP (False Positive - хибнопозитивний) виникає, коли модель помилково прогнозує позитивний клас.
4. FN (Хибнонегативний) виникає, коли модель помилково прогнозує негативний клас замість позитивного.

Фундаментальні метрики, що виводяться з цих значень:

1. Точність: це просто частка правильних прогнозів, зроблених класифікатором. Формула точності має вигляд:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Рисунок 3.5 – Формула точності

Джерело: побудовано автором на основі [24]

2. Прецизійність: Ця метрика відображає, скільки з позитивних ідентифікацій були насправді правильними. Точність розраховується за допомогою:

$$\text{Precision} = \frac{TP}{TP + FP}$$

Рисунок 3.6 – Формула прецизійності

Джерело: побудовано автором на основі [24]

3. Повнота: Це відношення фактичних позитивних ідентифікацій, які були правильно ідентифіковані. Відтворення розраховується як:

$$\text{Recall} = \frac{TP}{TP + FN}$$

Рисунок 3.7 – Формула повноти

Джерело: побудовано автором на основі [24]

4. Оцінка F1: Комбінований показник, який надає рівну вагу точності та відгуку. Формула має вигляд:

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

Рисунок 3.8 – Формула оцінки F1

Джерело: побудовано автором на основі [24]

Оцінка F1 корисна в ситуаціях, коли важливі і точність, і пригадування, додаткові дані не впливають на результат, або коли ціна хибнонегативного результату висока[34].

3.5 Реалізація моделей VGG16, InceptionV3 та MobileNetV2

VGG16

Модель VGG16 є відомою моделлю для класифікації зображень. Вона відзначилася на престижному конкурсі ILSVRC 2014[7] і досі широко визнана як модель, що докорінно змінила наше розуміння згорткових мереж. Розроблена групою візуальної графіки Оксфордського університету, VGG16 вдосконалила і без того надійний стандарт AlexNet[17] і відіграла важливу роль у вирішенні завдань класифікації того часу, структура яких зображена на рисунку 3.9.

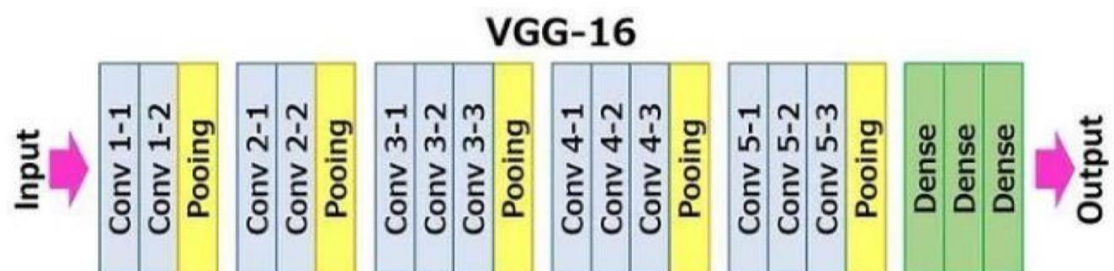
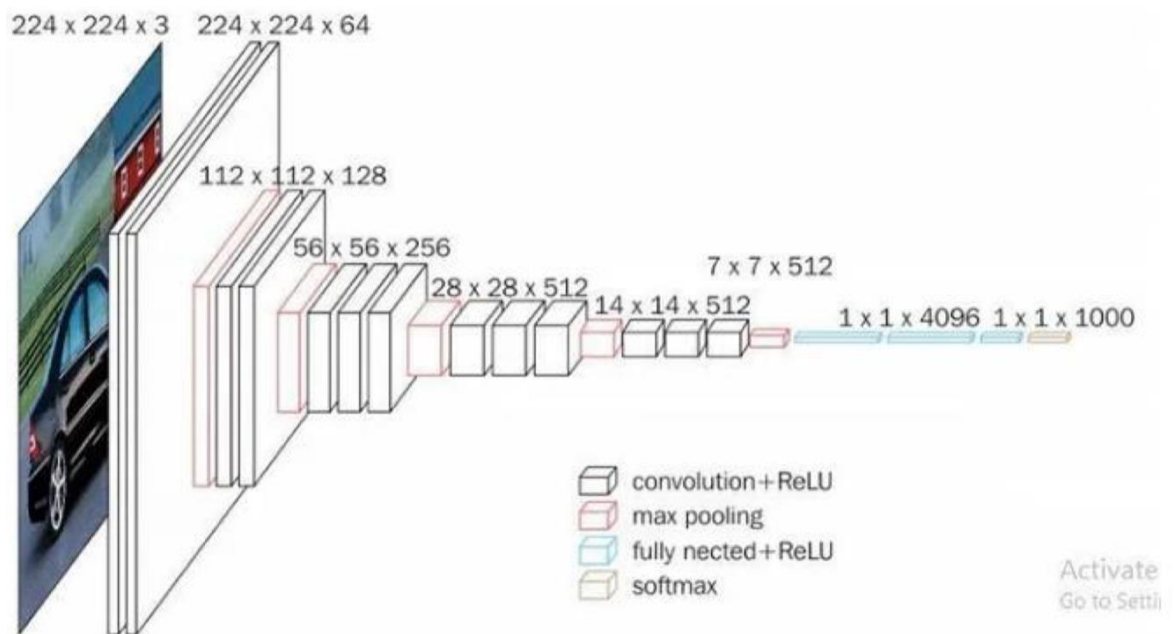


Рисунок 3.9 – Архітектура VGG16

Джерело: [7]

Вхідним шаром VGG16 є тензор зображення розміром 224x224 пікселі з 3 колірними каналами RGB. Однією з його відмінних характеристик є те, що він використовує значну кількість гіперпараметрів, переважно зосереджених у шарах згортки, які використовують фільтри 3x3 з кроком 1 і завжди використовують однакову прокладку для збереження просторової роздільної здатності, за якими йде шар максимального об'єднання з фільтром 2x2 і кроком 2.

Таке розташування шарів згортки та максимального об'єднання є послідовним для всієї архітектури. Зокрема, шар Conv-1 містить 64 фільтри, Conv-2 - 128 фільтрів, Conv-3 - 256 фільтрів, а шари Conv-4 і Conv-5 містять по 512 фільтрів.

Далі йдуть три повністю з'єднані шари, перші два з яких мають по 4096 каналів, а третій завершується шаром softmax на 1000 напрямків, який передбачає класифікацію на 1000 різних категорій - по одній для кожного класу. Фінальним шаром є шар softmax.

Кілька ключових моментів про модель:

- Вона є досить ресурсоємною з точки зору обчислювальних вимог; оригінальна модель VGG, що навчалася на графічних процесорах Nvidia Titan, зазвичай займала кілька тижнів.

- Розмір моделі для ваг VGG16, що зберігається в базі даних ImageNet, становить близько 528 МБ. Такий розмір означає значні витрати як на зберігання, так і на обчислення, що призводить до неефективності в деяких сценаріях.

Inception (GoogleNet)

Inception[8] , також відома як GoogleNet, - це нейромережева архітектура, яка здійняла хвилю на конкурсі ILSVRC 2014 року, встановивши новий рекорд за низьким рівнем помилок у задачі класифікації набору даних ImageNet. У порівнянні

з VGGNet, мережі Inception (GoogleNet/Inception v1) виявилися більш ефективними з точки зору кількості параметрів, що означає як обчислювальні, так і економічні переваги (наприклад, пам'ять та інші ресурси). Щоразу, коли необхідна модифікація, щоб уникнути значного обчислювального перевантаження, адаптивна архітектура Inception дозволяє використовувати її в різних додатках без шкоди для ефективності. Структура архітектури InceptionV3 від GoogleNet зображена на рисунку 3.10.

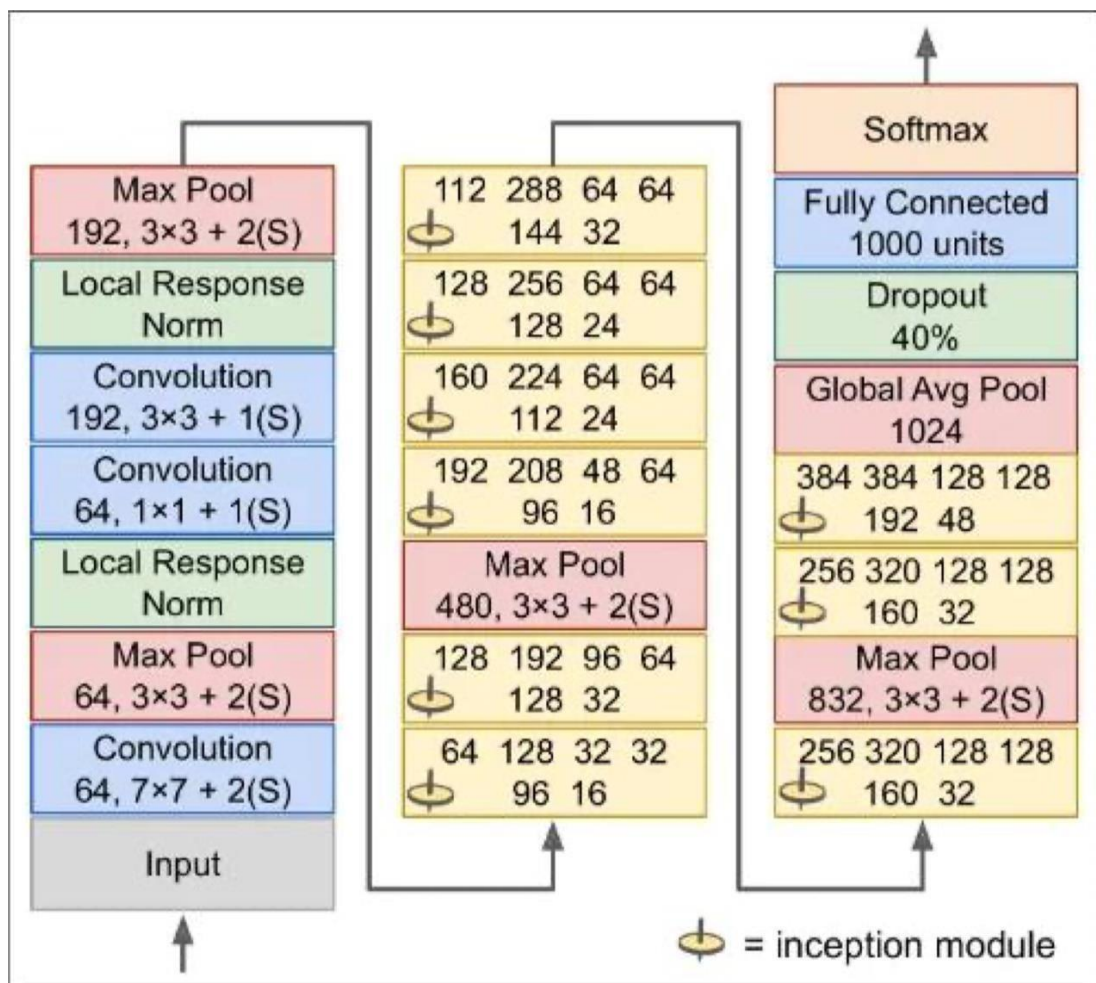


Рисунок 3.10 – Архітектура InceptionV3 від GoogleNet

Джерело: [8]

Архітектура GoogleNet складається з декількох ключових елементів, описаних нижче:

1. Перші два шари відповідають за зменшення розміру вхідного зображення з чотирьох разів у кожному вимірі до шістнадцяти разів загалом, що зменшує обчислювальне навантаження.

2. Далі йде шар локальної нормалізації відгуку, що є спадщиною попередніх архітектур, спрямованих на покращення чіткості сформованих зображень.

3. Далі йдуть два шари згортки, причому перший шар нагадує традиційну згорткову карту.

4. За ним знову йде шар локальної нормалізації відгуку.

5. Потім зображення піддається шару максимального об'єднання, який ще більше зменшує розміри для підготовки до більш складних наступних шарів.

6. Мережа продовжується серією початкових модулів, які використовують комбінацію згорток з максимальним об'єднанням для зменшення просторових розмірів без втрати важливих характеристик.

7. Передостаннім кроком мережі є застосування глобального усередненого шару об'єднання.

8. Останній шар відповідає за класифікацію, використовуючи повністю з'єднаний шар, за яким слідує шар `softmax` для визначення ймовірності кожного класу.

Більше того, сам початковий модуль інкапсулює в собі можливість одночасно фіксувати ознаки на різних масштабах, реалізуючи паралельні шляхи зі згортками різного розміру та гілкою максимального об'єднання, кожна з яких подається в операцію глибинної конкатенації. Опис модулів та гілок зображено на рисунку 3.11.

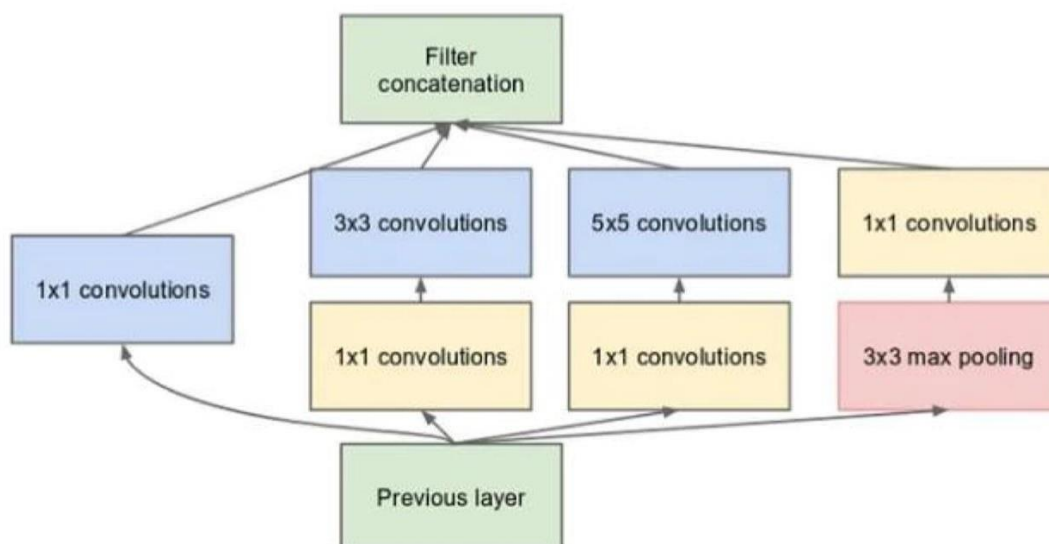


Рисунок 3.11 – Початковий модуль

Джерело: [8]

Початковий модуль починається зі згортки 1x1 для зменшення розмірності, після чого йдуть паралельні шляхи, які включають згортки 3x3 і 5x5, а також максимальне об'єднання 3x3, якому передують згортка 1x1 для зменшення глибини. Цей підхід відомий як глобальне середнє об'єднання: згортка 1x1 з подальшим середнім об'єднанням, в результаті чого отримуємо векторний результат для класифікації.

Ця архітектура усуває потребу в численних щільно пов'язаних шарах, які можна знайти в таких мережах, як AlexNet, значно зменшуючи кількість параметрів і ризик надмірного припасування.

MobileNetV2

MobileNetV2 - це ефективна згорткова нейронна мережа, створена для виконання на пристроях з обмеженими обчислювальними ресурсами, зокрема смартфонах, вбудованих системах і браузерах[9]. Вона є вдосконаленням оригінальної архітектури MobileNet, але суттєво перевершує її за точністю та стабільністю, при цьому зберігаючи головну перевагу — компактність і швидкість. У центрі концепції MobileNetV2 лежить особливий тип блоку, який отримав назву

"інвертований залишковий блок". Це кардинально новий підхід до структурування шарів, який, на відміну від класичних залишкових блоків, починається з розширення ознак за допомогою 1×1 згортки, далі застосовує глибоку просторову обробку через *depthwise* згортку 3×3 , і після цього стискає простір назад до вузької проекції, також 1×1 згорткою. Цей останній крок навмисне позбавлений активації, щоб уникнути втрати інформації в обмеженому інформаційному просторі — саме тому така проекція називається лінійною.

Особливою інновацією MobileNetV2 є те, що залишкові зв'язки в ній застосовуються не до широкого простору ознак, як у ResNet, а до вузького — тобто залишкове з'єднання йде між вхідним і вихідним шаром проекції, що значно знижує кількість параметрів. Якщо розмірності вхідного та вихідного тензорів збігаються, цей блок додає результат до вхідного сигналу, що дозволяє інформації "протікати" крізь мережу з мінімальними перешкодами. Таким чином, інвертовані залишкові блоки поєднують у собі ідею глибокої обробки ознак, ідею ефективного стиснення та принцип прямого потоку інформації.

Уся архітектура MobileNetV2 — це послідовність таких блоків із різними коефіцієнтами розширення та кількістю каналів, починаючи від початкової звичайної згортки 3×3 , що зменшує просторовий розмір зображення, і закінчуючи глобальним середнім згортанням (*global average pooling*) і підсумковим класифікатором. Незалежно від розміру вхідного зображення, останній шар завжди подає на вхід щільному шару вектор фіксованого розміру, який і класифікується за допомогою *softmax*. У випадку ImageNet мережа передбачає 1000 класів, але її легко адаптувати для інших задач, змінюючи лише розмір останнього шару.

MobileNetV2 проектувалася з урахуванням специфіки розгортання на реальних пристроях, тому підтримує квантовані операції, апаратне прискорення і виконання в середовищах на зразок TensorFlow Lite.

Ще однією перевагою є її виняткова гнучкість: за допомогою параметрів масштабу ширини та роздільної здатності модель можна налаштувати для ще більш легких варіантів використання — наприклад, для пристроїв з дуже обмеженим

обсягом пам'яті або процесора. У порівнянні з Inception або VGG, MobileNetV2 показує схожі або навіть кращі результати на практичних задачах, маючи при цьому в десятки разів менше параметрів та обчислень.

Насамкінець, варто зазначити, що MobileNetV2 не просто зменшена версія класичних глибоких архітектур, а самостійна конструктивна парадигма, що демонструє, як глибоке навчання може бути ефективно адаптоване до реального апаратного обмеження.

Саме завдяки цьому MobileNetV2 широко застосовується в розпізнаванні об'єктів, класифікації зображень, детекції жестів і багатьох інших застосуваннях, де критично важливі швидкість, енергоефективність і якість.

Архітектура MobileNetV2 по шарах графічно віображена на рисунку 3.12.




Рисунок 3.12 – Архітектура MobileNetV2

Джерело: [10]

3.4 Обґрунтування попереднього навчання

Після обробки даних до розміру (224,224,3) було зроблено розподіл, виділивши 90% для навчання і 10% для тестування, щоб забезпечити високу якість результатів.

Початковий вибір, використаний для навчання, включає три різні моделі: VGG16, Inception-v3 та MobileNetV2.

Для прискорення навчання цих моделей буде використано трансферне навчання. Повторне використання моделі, попередньо навченої на іншій проблемі, розглядається як використання «трансферного навчання» для машинного навчання. Знання, отримані з попереднього завдання, можуть покращити прогнози нового завдання під час перенесення навчання.

Моделі, які навчатимуться на наборі даних ImageNet, матимуть параметр `include_top` зі значенням `False`. Це гарантує, що мережа не включатиме верхній шар/вихідний шар з попередньо навченої моделі, що дозволить нам визначити наш власний вихідний шар залежно від конкретного сценарію.

Моделі будуть скомпільовані з категоріальною функцією втрат перехресної ентропії, а оптимізація буде виконана за допомогою методу «Адама», який адаптує швидкість навчання для кожного параметра моделі. Такий підхід гарантує, що в процесі навчання модель може бути точно налаштована, щоб максимізувати метрику точності.

В кінці моделі навчаються з використанням наступних параметрів:

1. Навчальні дані.
2. Параметр `validation_split` буде встановлено на 0.1, що означає, що 10% навчальних даних буде використано для валідації, щоб запобігти надмірному пристосуванню моделей.
3. Кількість епох - 100.

4. Verbose - 1 (більше значення призведе до відображення більшої кількості інформації під час навчання моделі).

Зворотні виклики (перемикачі реверсу) - можуть допомогти у виявленні та виправленні помилок, які можуть виникнути наприкінці роботи моделі. У цьому випадку буде використовуватися дострокова зупинка, яка буде контролювати параметр точності на кожній епосі і зупиняти навчання, якщо після 10 епох не буде покращення точності. Також буде використовуватися перевірка моделі, яка після кожної епохи перевіряє значення точності, і тільки якщо є покращення, модель зберігається. Це робиться для того, щоб модель можна було перезавантажити після досягнення найточніших результатів.

Найкраща модель буде обрана на основі значень метрик у порівнянні з тестовими даними.

У рамках етапу Data Analysis мною проведено послідовну та ретельно структуровану підготовку зображень МРТ для задачі класифікації пухлин мозку. Спочатку я завантажив набір даних із відкритого джерела (Kaggle), який складався з двох основних папок: Training та Testing, кожна з яких містила підпапки із чотирма класами — *glioma*, *meningioma*, *pituitary* та *no tumor*. Ці зображення були перенесені до середовища Google Colab через Google Drive, де і розпочалася подальша обробка.

Для впевненості у правильності структури даних, я провів перевірку директорій, після чого кожне зображення зчитувалося за допомогою бібліотеки OpenCV, приводилося до єдиного формату розміру — 224 на 224 пікселі, а також нормалізувалося шляхом поділу на 255 для приведення значень пікселів до діапазону від 0 до 1. Колірна модель зображень була скоригована з BGR до RGB, що є стандартом для більшості архітектур глибокого навчання. У процесі обробки кожному зображенню автоматично присвоювалась мітка відповідно до назви підкаталогу, з якого воно було зчитане. Ці мітки конвертувалися у формат one-hot encoding, що забезпечувало правильну взаємодію з функцією втрат categorical_crossentropy під час навчання моделей.

Усі підготовлені зображення та їх відповідні мітки були зібрані у масиви X та Y , які надалі були перемішані для уникнення впливу послідовності даних.

Наступним етапом стало розділення вибірки на тренувальну та валідаційну частини за допомогою функції `train_test_split()`, де приблизно 90% даних було відведено для навчання, а решта 10 - для оцінки під час тренування.

У результаті цих дій сформовано повністю готовий до роботи датасет, сумісний зі структурою вхідних даних моделей VGG16, MobileNetV2 та InceptionV3. Цей підготовчий етап відіграв критичну роль у забезпеченні якості подальшого навчання нейронних мереж, забезпечуючи однорідність, стандартизацію та збалансованість даних.

Після завершення етапу попередньої обробки даних, наступним важливим компонентом роботи стала реалізація функцій візуалізації навчального процесу моделей та перевірки їх ефективності. Цей крок мав на меті надати наочне уявлення про динаміку точності й втрат під час тренування, а також дозволити порівняти результати між трьома архітектурами нейронних мереж - VGG16, MobileNetV2 та InceptionV3.

У коді я створив окрему функцію `plot_training_history(history, title_prefix="Model")`, яка використовувалась для візуалізації результатів навчання кожної моделі. Вона приймає на вхід об'єкт `history`, що генерується в процесі тренування моделі методом `.fit()`, і витягує з нього ключові метрики: точність (`accuracy`), втрати (`loss`), а також валідаційну точність (`val_accuracy`) і валідаційні втрати (`val_loss`).

Ці дані виводяться у вигляді двох графіків на одному полотні: зліва - графік точності, справа - графік функції втрат. Такий підхід дозволяє наочно відслідковувати, чи досягає модель стабільного навчання, чи має місце перенавчання (`overfitting`), або навпаки — недостатнє навчання (`underfitting`).

Для збереження візуального контролю над тренуванням кожної з моделей, ця функція була викликана тричі з відповідними префіксами:

- title_prefix="VGG16"
- title_prefix="MobileNet2"
- title_prefix="InceptionV3"

Ці графіки відіграли ключову роль у подальшому аналізі стабільності й ефективності навчання моделей.

Окрім цього, у коді були закладені також базові callback-функції, такі як EarlyStopping та ModelCheckpoint, які не лише контролюють точність і втрати під час тренування, а й дозволяють автоматично зупинити навчання у випадку погіршення валідаційної якості, або зберегти найкращу версію моделі відповідно до обраного критерію. Таким чином, система автоматично відслідковувала процес тренування, зберігаючи оптимальні ваги та запобігаючи перенавчанню.

Завдяки цим візуалізаційним інструментам і callback-механізмам вдалося забезпечити прозорість процесу тренування моделей, що стало основою для подальшої об'єктивної оцінки їхньої продуктивності на тестових даних.

У наступному етапі відбувається безпосереднє тестування і порівняння результатів, включно з побудовою матриць неточностей, оцінкою точності класифікації та аналізом потенційних помилок.

3.5 Оцінка результатів: метрики точності, f1 рахунок, матриця плутанини

Після завершення етапів тренування моделей і візуалізації їх навчальних характеристик, відбувся ключовий етап - тестування та оцінка якості класифікації. Цей розділ роботи мав на меті об'єктивно порівняти ефективність трьох згорткових нейронних мереж, а саме: VGG16, MobileNetV2 та InceptionV3 на основі узагальненої здатності до класифікації нових, раніше невідомих зображень МРТ.

Для оцінки продуктивності моделей я використав такі класичні інструменти з пакету `sklearn.metrics`, як:

- `classification_report()` для генерації докладного звіту, що містить точність (`precision`), повноту (`recall`), F1-міру та загальну точність (`accuracy`) для кожного класу;
- `confusion_matrix()` для побудови матриці неточностей, яка дозволяє візуально оцінити кількість правильних і помилкових передбачень для кожного типу пухлини;
- `accuracy_score()` як інтегральна міра загальної точності передбачення на тестовому наборі.

Після тренування кожної з моделей, їхні ваги були використані для передбачення міток на тестовому наборі: `y_pred = model.predict(X_test)` з подальшим перетворенням вихідного формату через `np.argmax()`, що дозволяло отримати остаточні передбачення класів. Ці передбачення порівнювались із істинними мітками `y_true`, що дозволило оцінити ступінь відповідності.

Кожна модель генерувала власний звіт, який дозволив побачити:

- Які саме класи класифікуються найкраще (наприклад, `pituitary` або `glioma`);
- Де найчастіше виникають помилки (наприклад, часте змішування `glioma` з `meningioma`);
- Наскільки добре модель балансує точність і повноту по кожному класу.

Для ще більшої наочності отримані матриці неточностей могли бути візуалізовані у вигляді теплових карт (`sns.heatmap()`), що дало змогу швидко оцінити, де саме виникають слабкі місця в роботі моделі.

Ці аналітичні підсумки стали основою для фінального висновку щодо ефективності кожної архітектури.

Результати VGG16

Результати роботи моделі VGG16 показано на Рисунку 22. На 87-й епосі модель закінчила своє навчання, оскільки за останні 10 епох не відбулося покращення значення точності.

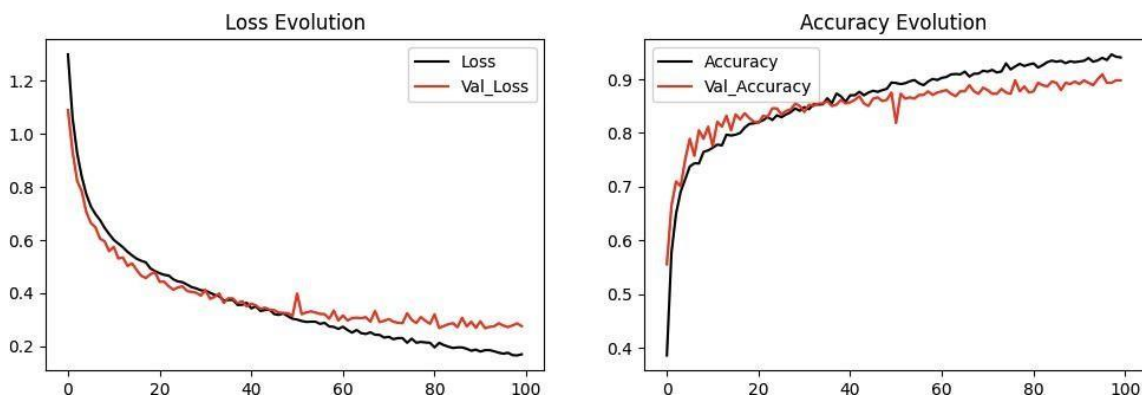


Рисунок 3.13 – Історія навчання VGG16

Джерело: побудовано автором на основі даних [11]

На графіку втрат (Loss) видно чітке зменшення як навчальної (Loss), так і валідаційної (Val_Loss) похибки протягом перших ~60 епох. Подальше згладжування без серйозних коливань свідчить про відсутність переобучення.

На графіку точності (Accuracy) також спостерігається швидке зростання до 80% вже на 10-й епосі, далі — плавне наближення до фінального значення 91%. Валідаційна точність слідує за тренувальною дуже близько, що підтверджує узгодженість моделі.

Далі переходжу до оцінки роботи моделі на тестовому наборі даних, результати якого зображено на рисунках 3.14 і 3.15.

	precision	recall	f1-score	support
0	0.87	0.89	0.88	94
1	0.93	0.86	0.89	105
2	0.96	0.93	0.95	46
3	0.91	0.98	0.94	82
accuracy			0.91	327
macro avg	0.91	0.92	0.91	327
weighted avg	0.91	0.91	0.91	327

Accuracy score: 0.908256880733945

Рисунок 3.14 – метрики тестових даних VGG16

Джерело: побудовано автором на основі даних [11]




Рисунок 3.15 – Матриця плутанини для VGG16 (тестові дані)

Джерело: побудовано автором на основі даних [11]

Модель демонструє сильну класифікацію meningioma (90 правильних з 105) та pituitary (80 із 82). Найбільші помилки припадають на:

1. glioma, який іноді плутається з meningioma;
2. no tumor, який 6 разів помилково класифікується як glioma або meningioma.

Це свідчить про наявність візуальної схожості між benign і malignant випадками або особливості в даних.

Модель VGG16 показала відмінні результати, досягнувши загальної точності 91%, стабільного навчання без переобучення, а також високих значень F1-міри по кожному класу.

Незважаючи на деякі змішані передбачення між glioma та meningioma, модель впевнено ідентифікує більшість випадків безпомилково. Її використання може бути ефективним у практичних сценаріях, особливо коли потрібна стабільність і пояснюваність результатів.

Результати Inception-v3

Модель InceptionV3, відома своєю складною багаторівневою архітектурою з інсепшн-блоками, була протестована на тому самому датасеті для задачі класифікації пухлин головного мозку. Завдяки своїй глибокій структурі вона здатна захоплювати багатовимірні просторові патерни, але це не завжди гарантує найвищу ефективність у завданнях із обмеженим обсягом даних, що й продемонстрували результати.

Результати моделі Inception-v3 показано на рисунку 3.16:

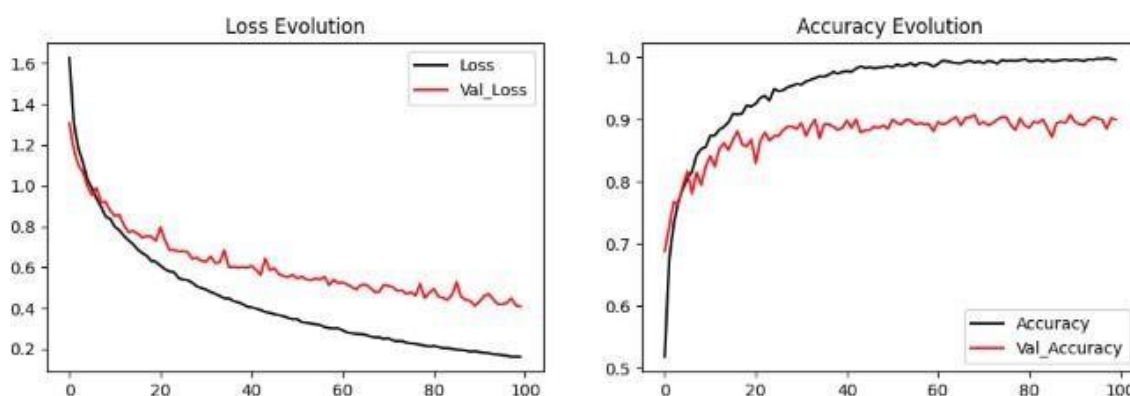


Рисунок 3.16 – Історія навчання InceptionV3

Джерело: побудовано автором на основі даних [11]

Модель продемонструвала хорошу точність, проте дещо нижчу порівняно з VGG16. Особливо помітна нерівномірність у класифікації різних класів, що проявляється в деталях матриці неточностей.

Графік втрат (Loss Evolution) вказує на повільне, але стійке зниження втрат протягом усього періоду тренування (100 epoch), при цьому валідаційна похибка демонструє легкі коливання, що може вказувати на зростаючу нестабільність або перенавчання ближче до кінця.

Графік точності (Accuracy Evolution) демонструє швидке покращення протягом перших 20 epoch, після чого модель виходить на плато з тренувальною точністю >95%, але валідаційна точність стабілізується на рівні ~89–90% і не покращується далі.

Рисунок 31 ілюструє еволюцію втрат і точності. Тепер подивимося на роботу моделі на тестових даних (показано на рисунку 3.17 і 3.18):

```

                precision    recall  f1-score   support

     0             0.91         0.86         0.89         94
     1             0.89         0.90         0.90        105
     2             0.93         0.93         0.93         46
     3             0.92         0.95         0.93         82

 accuracy
macro avg             0.91         0.91         0.91        327
weighted avg          0.91         0.91         0.91        327

Accuracy score: 0.908256880733945

```

Рисунок 3.17 – метрики тестових даних InceptionV3

Джерело: побудовано автором на основі даних [11]

На рисунку 26 представлено метрики на тестових даних для Inception-v3, де показано таблицю з точністю, запам'ятовуванням і оцінкою F1 для різних класів, а також загальну точність 90%.

Модель в основному справляється добре, однак видно деяке перекриття між glioma та meningioma, а також випадки помилкової класифікації "no tumor" - що є критично чутливим класом у медичній практиці. Це знижує довіру до моделі в умовах, де фальшиво-позитивні або фальшиво-негативні випадки мають значення для життя пацієнта.




Рисунок 3.18 – Матриця плутанини для InceptionV3 (тестові дані)

Джерело: побудовано автором на основі даних [11]

InceptionV3 показує гідну точність (~90%), стабільне навчання і сильні загальні метрики, проте за результатами трохи поступається VGG16. Це може бути пов'язано з її високою складністю, що не виправдана для даного масштабу задачі та обсягу даних.

Модель працює добре, але має схильність до надмірного навчання (overfitting), а також більше помилок при класифікації "no tumor", що критично для медичних систем.

Результати MobileNetV2

Модель MobileNetV2, яка була оптимізована для ефективності й швидкодії, показала виняткову здатність до точного розпізнавання пухлин мозку на основі МРТ-знімків. Завдяки своїй архітектурі, орієнтованій на мобільні пристрої та обмежені обчислювальні ресурси, модель досягла дуже високої якості класифікації при суттєвому зменшенні часу тренування.

Результати моделі MobileNetV2 представлені на рисунку 3.19:

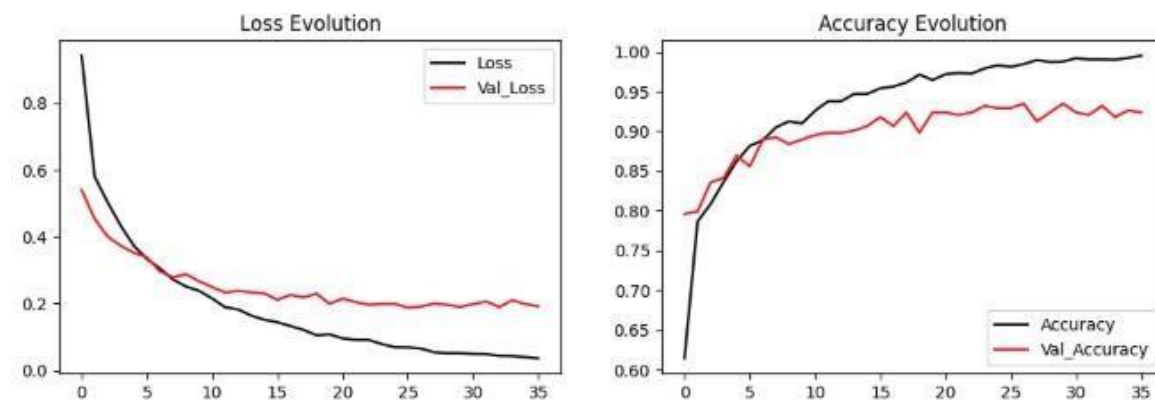


Рисунок 3.19 – Історія навчання MobileNetV2

Джерело: побудовано автором на основі даних [11]

Модель продемонструвала високу збалансовану точність по всіх класах, із лише незначними коливаннями в окремих категоріях. Особливо варто підкреслити, що вона стабільно досягає >92% точності вже після 30 епох.

Графік втрат (Loss Evolution) демонструє плавне та стабільне зниження навчальної похибки, з паралельною стабільною динамікою валідаційної втрати після приблизно 10-ї епохи.

Графік точності (Accuracy Evolution) вказує на швидке зростання точності до ~90% вже на 5-й епосі, після чого точність продовжує зростати повільно, досягаючи ~97% на тренуванні та ~92% на валідації, що говорить про хорошу здатність до узагальнення без ознак перенавчання.

	precision	recall	f1-score	support
0	0.93	0.90	0.92	94
1	0.91	0.89	0.90	105
2	0.93	0.93	0.93	46
3	0.92	0.99	0.95	82
accuracy			0.92	327
macro avg	0.93	0.93	0.93	327
weighted avg	0.92	0.92	0.92	327

Accuracy score: 0.9235474006116208

Рисунок 3.20 – метрики тестових даних MobileNetV2

Джерело: побудовано автором на основі даних [11]

На рисунку 3.20 показано метрики тестових даних для MobileNetV2 з таблицею, що включає точність, запам'ятовування та оцінку F1 для різних класів, а загальна точність становить майже 93%. Порівняно з попередньою нейронною мережею, значення метрик зросло та загальна точність суттєво вища.




Рисунок 3.21 – Матриця плутанини для MobileNetV2 (тестові дані)

Джерело: побудовано автором на основі даних [11]

Модель MobileNetV2 чудово справляється з класифікацією pituitary (81 з 82) та no tumor (43 з 46). Помилки присутні, але вони мінімальні — найбільші змішування фіксуються між glioma та meningioma, що типово для задач такого типу через візуальну подібність окремих знімків.

MobileNetV2 показує високу точність, стабільне навчання та відмінне узагальнення, досягаючи результатів, які навіть трохи перевищують показники VGG16 (92.35% проти 91%). Модель демонструє дуже ефективне співвідношення продуктивності та обчислювальної складності, що робить її особливо привабливою для впровадження в системи з обмеженими ресурсами (мобільні пристрої, польова медицина тощо). Враховуючи її стабільність та швидке навчання, вона є дуже перспективною в реальних умовах використання.

3.6 Порівняльний аналіз моделей та вибір найефективнішої

Проведене дослідження з класифікації пухлин головного мозку на основі МРТ-знімків із використанням трьох популярних згорткових нейронних мереж — VGG16, MobileNetV2 та InceptionV3 — дозволяє зробити чіткий порівняльний аналіз їх ефективності, стабільності та придатності для практичного використання, особливо в умовах обмежених ресурсів.

Модель VGG16 показала стабільні та високі результати, досягнувши точності 91% на тестових даних. Вона продемонструвала хорошу збалансованість між класами, з мінімальними перекриттями в матриці неточностей. Зокрема, модель ефективно класифікувала такі класи, як *meningioma* та *pituitary*, хоча часом помилково плутала *glioma* з іншими типами. Навчання було стабільним, без ознак переобучення, що підтверджується плавними графіками втрат та точності. Її класична архітектура дозволяє легко пояснювати рішення моделі, що є додатковим плюсом у медичному контексті. Однак VGG16 вимагає більше обчислювальних ресурсів і часу на тренування, ніж легші моделі.

MobileNetV2 продемонструвала найвищу продуктивність серед усіх моделей, досягнувши точності понад 92.3%. Це особливо вражає з урахуванням її компактної, оптимізованої архітектури. Вона забезпечує не лише швидке навчання та інференс, але й виняткову точність класифікації майже всіх класів. Графіки втрат і точності свідчать про швидку збіжність та відсутність ознак перенавчання.

Модель виявилася найменш чутливою до візуальних схожостей між класами, а також більш стійкою до класифікації класу “no tumor” — що критично важливо для уникнення помилкових діагнозів. Це робить MobileNetV2 найкращим кандидатом для практичного впровадження, особливо в телемедицині та мобільних системах.

Натомість InceptionV3, хоча і показала достойні результати (загальна точність — 90%), поступилася двом попереднім моделям. Незважаючи на свою потужну інсепшн-архітектуру, вона демонструвала більші коливання валідаційної точності, що може свідчити про дещо гіршу здатність до узагальнення. Помітне перекриття між *glioma* та *meningioma*, а також випадки помилкової класифікації “no tumor” знижують її надійність для клінічного застосування. Крім того, InceptionV3 виявилася найважчою з точки зору обчислювальної складності, потребувала більше часу на тренування, і не продемонструвала суттєвої переваги в точності, яка могла би виправдати її використання.

Підсумовуючи, можна стверджувати, що MobileNetV2 є найбільш збалансованим і практично ефективним варіантом, що поєднує високу точність, стабільність, швидкість та адаптивність до різних обчислювальних середовищ. VGG16 також залишається надійним рішенням, особливо в умовах стаціонарного використання з достатнім ресурсним забезпеченням. InceptionV3, хоч і має сильний архітектурний потенціал, у цьому завданні не змогла повністю розкрити свої можливості, і, ймовірно, краще підходить для задач із більшим обсягом даних та вищою візуальною різноманітністю.

Всі нейронні мережі показали хороші результати без обширної попередньої обробки, необхідної для інших методів машинного навчання. Це демонструє переваги глибокого навчання для задач класифікації пухлин головного мозку, як зазначають J. Seetha і S. Selvakumar Raja у своєму дослідженні.

Загалом, дослідження успішно продемонструвало розробку програмного продукту на основі нейронної мережі, розробленого для послідовного виявлення та класифікації пухлин мозку. Результати оцінювання показують ключову здатність програмного забезпечення точно виконувати завдання класифікації «немає пухлини» та хороші результати ідентифікації для інших типів пухлин, представлених у дослідженні. Цей інструмент демонструє значне вдосконалення рішень у галузі охорони здоров'я в слаборозвинутих країнах і країнах, що

розвиваються, де такі вдосконалені діагностичні можливості можуть суттєво вплинути на лікування пацієнтів, враховуючи обмеження місцевих ресурсів.

Протягом усього процесу розробки впровадження зворотних викликів і контрольних точок моделі було вирішальною частиною стійкості та надійності моделей. Ці методи забезпечили ефективність і стійкість навчального процесу до збоїв, що є важливою особливістю для районів з ненадійною інфраструктурою. Використовуючи зворотні виклики, модель постійно оптимізується, дозволяючи автоматично зберігати прогрес і можливість повернутися до найкращого стану, якщо це необхідно. Контрольні точки моделі забезпечили гнучкість для підтримки навчання в різних умовах, гарантуючи, що найнадійніша версія моделі завжди зберігається без необхідності повторного та ресурсомісткого перенавчання.

Здатність програмного забезпечення адаптуватися до різноманітних наборів даних і вдосконалюватися завдяки додатковому навчанню особливо корисна для регіонів з різними медичними потребами та обмеженим доступом до великих анотованих наборів даних.

Крім того, потенційне розширення класів пухлин і здатність обробляти більші набори даних підкреслюють масштабованість програмного забезпечення, що має важливе значення для охоплення широкого діапазону патологічних сценаріїв, які зазвичай зустрічаються в цих країнах. Така функціональність демонструє довгострокове, стійке прийняття рішень програмним забезпеченням для діагностики пухлин мозку.

Найкраща досягнута точність становила 93%, тоді як галузь медицини зазвичай вимагає мінімальної точності 97% для діагностики, що залежить від життя. Проте найкраща модель продемонструвала надзвичайну продуктивність, впоравшись із майже 100% категорією «немає пухлини». Ця віха має вирішальне значення в контексті нерозвинених країн і країн, що розвиваються, де відсутність або наявність пухлини є абсолютним ключем. Це відображає прагнення забезпечити рівень діагностичної точності, який відповідає суворим вимогам медичних застосувань, де високі ставки.

3.7 Подальші напрями удосконалення запропонованого методу

Запропонований підхід до автоматизованого виявлення пухлин головного мозку на основі згорткових нейронних мереж є ефективним і показує високі результати за точністю класифікації. Проте існують напрямки, що дозволяють істотно підвищити якість, адаптивність і практичну цінність системи.

Перш за все, доцільно розширити навчальний датасет за рахунок додаткових медичних зображень із різних джерел, що сприятиме зниженню ймовірності перенавчання та підвищенню узагальнювальної здатності моделей. Особливу увагу варто звернути на баланс класів у вибірці, адже наявна диспропорція між типами пухлин може впливати на об'єктивність результатів.

Другим напрямом удосконалення є впровадження методів слабо контрольованого або напівавтоматизованого навчання, що дозволить використовувати неповно анотовані або частково марковані медичні знімки, зменшуючи залежність системи від ручної розмітки.

Технічно перспективним є також розширення архітектури нейронної мережі шляхом інтеграції модулів сегментації, що дасть змогу не лише класифікувати наявність пухлини, а й точно локалізувати її межі на зображенні.

З точки зору практичної реалізації, важливим є адаптація моделі до мобільних або вбудованих пристроїв із обмеженими ресурсами. Це дозволить впроваджувати рішення на рівні телемедичних платформ, медичних інформаційних систем або як частину мобільних застосунків для попереднього медичного скринінгу.

У контексті інтеграції в клінічну практику перспективним є створення інтерфейсу для взаємодії лікаря з результатами моделі, що забезпечить візуалізацію діагностичних висновків і рівень впевненості прогнозу. Це підвищить довіру до системи й дозволить лікарю використовувати її як допоміжний інструмент у процесі прийняття рішень.

Таким чином, подальше удосконалення запропонованого методу повинно бути спрямоване на підвищення точності, інтерпретованості та гнучкості моделі, що дозволить ефективно впроваджувати її у практичну медицину, зокрема в умовах обмежених ресурсів.

ВИСНОВКИ

Магістерська робота висвітлює розробку програмного продукту на основі нейронних мереж, призначеного для послідовного виявлення та класифікації пухлин головного мозку. Розроблене програмне забезпечення демонструє здатність виконувати завдання класифікації «немає пухлини» та ідентифікує чотири типи пухлин. Основні результати роботи такі:

1. Проведено огляд традиційних методів діагностики та обґрунтовано доцільність їх доповнення автоматизованими системами на основі штучного інтелекту, що актуально в умовах обмежених медичних ресурсів.

2. Проаналізовано принципи функціонування згорткових нейронних мереж та структури архітектур VGG16, MobileNetV2 та InceptionV3, що застосовуються для класифікації зображень.

3. Реалізовано повний цикл створення діагностичної моделі: підготовку медичного датасету, обробку зображень, нормалізацію та використання зворотних викликів і контрольних точок у процесі навчання.

4. Проведено навчання та тестування моделей VGG16, MobileNetV2 та InceptionV3. Для оцінювання результатів застосовано метрики точності, повноти, F1-міри та побудовано матриці плутанини.

5. Проведений порівняльний аналіз моделей який показав, що архітектура MobileNetV2 демонструє високу точність при невисоких обчислювальних ресурсах, що робить її найбільш придатною для використання у країнах із обмеженими ресурсами.

Запропонована система може бути інтегрована в телемедичні платформи або мобільні пристрої, що розширює доступ до діагностики в сільських та віддалених регіонах. Результати дослідження мають практичне значення для закладів охорони здоров'я, що прагнуть підвищити точність і ефективність діагностики, а також для подальших наукових розробок у галузі медичного штучного інтелекту.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Litjens G. et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*. 2017. URL: <https://doi.org/10.1016/j.media.2017.07.005> (date of access: 25.03.2025).
2. Monocular Depth Estimation in Computer Vision. Viso.ai. URL: <https://viso.ai/computer-vision/monocular-depth-estimation/> (date of access: 25.03.2025).
3. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. 2015. 521:436–444. URL: <https://www.nature.com/articles/nature14539> (date of access: 22.03.2025).
4. Kermany D. S. et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*. 2018. URL: <https://doi.org/10.1016/j.cell.2018.02.010> (date of access: 24.03.2025).
5. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *NeurIPS*. 2012. URL: https://papers.nips.cc/paper_files/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html (date of access: 22.03.2025).
6. Basic CNN Architecture Explained. upGrad. URL: <https://www.upgrad.com/blog/basic-cnn-architecture/> (date of access: 22.03.2025).
7. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv:1409.1556. URL: <https://arxiv.org/abs/1409.1556> (date of access: 21.03.2025).
8. Szegedy C. et al. Rethinking the Inception Architecture for Computer Vision. arXiv:1512.00567. URL: <https://arxiv.org/abs/1512.00567> (date of access: 22.03.2025).
9. Sandler M., Howard A., Zhu M. et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks. arXiv:1801.04381. URL: <https://arxiv.org/abs/1801.04381> (date of access: 21.03.2025).

10. Deng J. et al. ImageNet: A Large-Scale Hierarchical Image Database. *CVPR*. 2009. URL: https://image-net.org/papers/imagenet_cvpr09.pdf (date of access: 20.03.2025).
11. Brain Tumor Classification (MRI). Kaggle. URL: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset> (date of access: 19.03.2025).
12. TensorFlow Documentation. URL: <https://www.tensorflow.org/> (date of access: 20.03.2025).
13. Keras Documentation. URL: <https://keras.io/> (date of access: 20.03.2025).
14. Chollet F. Deep Learning with Python. Manning Publications, 2017.
15. Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2016. URL: <https://www.deeplearningbook.org> (date of access: 19.03.2025).
16. Wang G. A perspective on deep imaging. *IEEE Access*. 2016. 4:8914–8924. URL: <https://doi.org/10.1109/ACCESS.2016.2617478> (date of access: 22.03.2025).
17. AlexNet: Introduction to Deep Learning Neural Networks. Viso.ai. URL: <https://viso.ai/deep-learning/alexnet/> (date of access: 25.03.2025).
18. Russakovsky O. et al. ImageNet Large Scale Visual Recognition Challenge. *IJCV*. 2015. URL: <https://arxiv.org/abs/1409.0575> (date of access: 20.03.2025).
19. Lundervold A. S., Lundervold A. An overview of deep learning in medical imaging. *Z Med Phys*. 2019. URL: <https://doi.org/10.1016/j.zemedi.2018.11.002> (date of access: 24.03.2025).
20. WHO. Cancer. URL: <https://www.who.int/news-room/fact-sheets/detail/cancer> (date of access: 25.03.2025).
21. Khan S. et al. A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*. 2020. URL: <https://doi.org/10.1007/s10462-019-09779-6> (date of access: 24.03.2025).
22. Mehta S., Rastegari M. MobileViT: Light-weight, General-purpose, and Mobile-friendly Vision Transformer. arXiv:2110.02178. URL: <https://arxiv.org/abs/2110.02178> (date of access: 22.03.2025).

23. OpenCV Documentation. URL: <https://docs.opencv.org/> (date of access: 20.03.2025).
24. Pedregosa F. et al. Scikit-learn: Machine Learning in Python. *JMLR*. 2011. URL: <https://scikit-learn.org/stable/about.html> (date of access: 23.03.2025).
25. Abiodun O.I. et al. Comprehensive review of artificial neural network applications to pattern recognition. *Applied Computational Intelligence and Soft Computing*. 2018. URL: <https://doi.org/10.1155/2018/1548959> (date of access: 22.03.2025).
26. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. arXiv:1505.04597. URL: <https://arxiv.org/abs/1505.04597> (date of access: 23.03.2025).
27. Jabeen S. et al. Brain tumor classification using CNN features. *Computers in Biology and Medicine*. 2020. URL: <https://doi.org/10.1016/j.compbimed.2020.103607> (date of access: 25.03.2025).
28. Esteva A. et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017. URL: <https://doi.org/10.1038/nature21056> (date of access: 21.03.2025).
29. Shorten C., Khoshgoftaar T.M. A survey on image data augmentation for deep learning. *J Big Data*. 2019. URL: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-019-0197-0> (date of access: 22.03.2025).
30. Mazurowski M. A. et al. Deep learning in radiology: An overview of the concepts and a survey of the state of the art. *Radiology: Artificial Intelligence*. 2019. URL: <https://pubs.rsna.org/doi/full/10.1148/ryai.2019180029> (date of access: 23.03.2025).
31. Huang G. et al. Densely Connected Convolutional Networks. *CVPR*. 2017. URL: <https://arxiv.org/abs/1608.06993> (date of access: 21.03.2025).
32. GitHub: Brain Tumor Classifier with CNN. URL: <https://github.com/topics/brain-tumor-classification> (date of access: 25.03.2025).

33. American Cancer Society. Key Statistics for Brain and Spinal Cord Tumors. URL: <https://www.cancer.org/cancer/types/brain-spinal-cord-tumors-adults/about/keystatistics.html> (date of access: 06.04.2024).
34. Cancer.Net Editorial Board. Brain Tumor: Statistics. Cancer.Net. URL: <https://www.cancer.net/cancer-types/brain-tumor/statistics> (date of access: 06.04.2024).
35. Cleveland Clinic. Neurosurgeon: What They Do, Specialties & Training. URL: <https://my.clevelandclinic.org/health/articles/22364-neurosurgeon> (date of access: 06.04.2024).
36. Sennaar K. How America's 5 Top Hospitals are Using Machine Learning Today. Emerj. URL: <https://emerj.com/ai-sector-overviews/top-5-hospitals-using-machinelearning/> (date of access: 06.04.2024)
37. Dana-Farber Cancer Institute. How We Diagnose Brain Tumors. URL: <https://www.dana-farber.org/cancer-care/types/brain-tumors/diagnosis> (date of access: 06.04.2024).
38. Sithara J., Selvakumar Raja S. Brain Tumor Classification Using Convolutional Neural Networks. International Journal of Advanced Computer Science and Applications, Vol. 13, No. 2, 2022. URL: https://thesai.org/Downloads/Volume13No2/Paper_62-Brain_Tumor_Classification_Using_CNN.pdf (date of access: 25.03.2025)
39. Baltrusaitis T., Ahuja C., Morency L.P. Multimodal Machine Learning: A Survey and Taxonomy. arXiv:1705.09406. URL: <https://arxiv.org/abs/1705.09406> (date of access: 25.03.2025).
40. Badrinarayanan V., Kendall A., Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. arXiv:1511.00561. URL: <https://arxiv.org/abs/1511.00561> (date of access: 25.03.2025).
41. Zhou Z.H. A brief introduction to weakly supervised learning. National Science Review, 2018. URL: <https://doi.org/10.1093/nsr/nwx103> (date of access: 25.03.2025).

42. Esteva A., Robicquet A., Ramsundar B. et al. A guide to deep learning in healthcare. *Nature Medicine*, 2019. URL: <https://www.nature.com/articles/s41591-018-0316-z> (date of access: 25.03.2025).
43. Lundervold A.S., Lundervold A. An overview of deep learning in medical imaging. *Z Med Phys*. URL: <https://doi.org/10.1016/j.zemedi.2018.11.002> (date of access: 25.03.2025).
44. Zeiler M.D., Fergus R. Visualizing and Understanding Convolutional Networks. *ECCV 2014*. URL: <https://arxiv.org/abs/1311.2901> (date of access: 25.03.2025).
45. Васильєв С. О. Основи глибокого навчання: методи та застосування. Київ: Наукова думка, 2021. 312 с.
46. Lin M., Chen Q., Yan S. Network In Network. arXiv:1312.4400. URL: <https://arxiv.org/abs/1312.4400> (date of access: 25.03.2025).
47. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. arXiv:1512.03385. URL: <https://arxiv.org/abs/1512.03385> (date of access: 25.03.2025).
48. Мельник Р. М. Нейронні мережі та їх використання для обробки зображень. *Комп'ютерні науки та інформаційні технології*, 2020, №2, с. 41–48.
49. Srivastava N. et al. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *JMLR*, 2014. URL: <https://jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf> (date of access: 25.03.2025).
50. Bengio Y. Learning Deep Architectures for AI. *Foundations and Trends in Machine Learning*, 2009. URL: https://www.iro.umontreal.ca/~bengioy/papers/ftml_book.pdf (date of access: 25.03.2025).
51. Ковальчук І. В., Бойко А. Ю. Застосування штучного інтелекту в медицині: сучасні виклики та перспективи. *Інформаційні технології в освіті, науці та техніці*, 2022, №1, с. 25–33.

52. Zhao Z., Chen W., Wu X. et al. Deep learning with XGBoost for brain tumor classification. *Frontiers in Oncology*, 2021. URL: <https://www.frontiersin.org/articles/10.3389/fonc.2021.672764/full> (date of access: 25.03.2025).



Звіт подібності

метадані

Назва організації

Kyiv National Economic University named after Vadym Hetman KNEU

Заголовок

Диплом_Толочко

Автор

Науковий керівник / Експерт


Толочко Володимир ВолодимировичПічкур В.В.

підрозділ

кафедра системного аналізу та кібербезпеки

Обсяг знайдених подібностей

Коефіцієнт подібності визначає, який відсоток тексту по відношенню до загального обсягу тексту було знайдено в різних джерелах. Зверніть увагу, що високі значення коефіцієнта не автоматично означають плагіат. Звіт має аналізувати компетентна / уповноважена особа.



КП 1

25

Довжина фрази для коефіцієнта подібності 2



КП 2

10141

Кількість слів



КЦ

78016

Кількість символів

Тривога

У цьому розділі ви знайдете інформацію щодо текстових спотворень. Ці спотворення в тексті можуть говорити про **МОЖЛИВІ** маніпуляції в тексті. Спотворення в тексті можуть мати навмисний характер, але частіше характер технічних помилок при конвертації документа та його збереженні, тому ми рекомендуємо вам підходити до аналізу цього модуля відповідально. У разі виникнення запитань, просимо звертатися до нашої служби підтримки.

Заміна букв		3
Інтервали		0
Мікропробіли		0
Білі знаки		0
Парафрази (SmartMarks)		11

Подібності за списком джерел

Нижче наведений список джерел. В цьому списку є джерела із різних баз даних. Копір тексту означає в якому джерелі він був знайдений. Ці джерела і значення Коефіцієнту Подібності не відображають прямого плагіату. Необхідно відкрити кожне джерело і проаналізувати зміст і правильність оформлення джерела.

10 найдовших фраз

Колір тексту

ПОРЯДКОВИЙ НОМЕР	НАЗВА ТА АДРЕСА ДЖЕРЕЛА URL (НАЗВА БАЗИ)	КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
1	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	30 0.30 %
2	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	20 0.20 %
3	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	12 0.12 %
4	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	12 0.12 %

5	Ruzhans`ka_diplom_mag_Vasyl`eva_fkn_2021.pdf 12/3/2021 V. N. Karazin Kharkiv National University (KGNU) (ННІ комп'ютерних наук та штучного інтелекту - кафедра комп'ютерних систем та робототехніки)	12 0.12 %
6	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	11 0.11 %
7	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	8 0.08 %
8	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	7 0.07 %
9	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	7 0.07 %
10	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	7 0.07 %

з бази даних RefBooks (0.00 %)



ПОРЯДКОВИЙ НОМЕР	ЗАГОЛОВОК	КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
------------------	-----------	--

з домашньої бази даних (0.00 %)



ПОРЯДКОВИЙ НОМЕР	ЗАГОЛОВОК	КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
------------------	-----------	--

з програми обміну базами даних (0.17 %)



ПОРЯДКОВИЙ НОМЕР	ЗАГОЛОВОК	КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
------------------	-----------	--

1	Ruzhans`ka_diplom_mag_Vasyl`eva_fkn_2021.pdf 12/3/2021 V. N. Karazin Kharkiv National University (KGNU) (ННІ комп'ютерних наук та штучного інтелекту - кафедра комп'ютерних систем та робототехніки)	17 (2) 0.17 %
---	--	---------------

з Інтернету (1.35 %)



ПОРЯДКОВИЙ НОМЕР	ДЖЕРЕЛО URL	КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
------------------	-------------	--

1	https://ela.kpi.ua/bitstreams/281e73b0-46b2-4b60-9c12-35efd188fc2b/download	137 (13) 1.35 %
---	---	-----------------

Список прийнятих фрагментів (немає прийнятих фрагментів)

ПОРЯДКОВИЙ НОМЕР	ЗМІСТ	КІЛЬКІСТЬ ОДНАКОВИХ СЛІВ (ФРАГМЕНТІВ)
------------------	-------	---------------------------------------