

Хмельницький національний університет
Факультет інформаційних технологій
Кафедра комп'ютерних наук

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

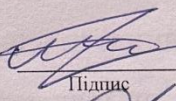
на тему Метод виявлення пухлин мозку на зображеннях МРТ
нейромережевими засобами

Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань
Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності
Освітня програма Комп'ютерні науки
Назва освітньої програми

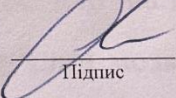
Виконав: студент 2 курсу, група КНм-23-2
Курс, група виконавця


Підпис Даніїл ГАРКАВІЮК
Ініціали, прізвище

Керівник: д.т.н., професор кафедри КН
Науковий ступінь, посада



Підпис Едуард
МАНЗІЮК
Ініціали, прізвище

Нормоконтроль: к.т.н., доцент кафедри КН
Науковий ступінь, посада


Підпис Руслан БАГРІЙ
Ініціали, прізвище

До захисту допускаю:

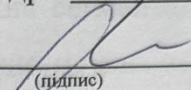
Зав. кафедри КН, д.т.н., професор


Підпис Олександр
БАРМАК
Ініціали, прізвище

17 грудня 2024 р.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
Факультет інформаційних технологій
Кафедра комп'ютерних наук
Освітній ступінь магістр
Галузь знань 12 – Інформаційні технології
Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ
Завідувач кафедри комп'ютерних наук


(підпис)
д.т.н., професор Олександр БАРМАК
« 02 » вересня 2024 року

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ МАГІСТРА**

1. Тема кваліфікаційної роботи магістра: «Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами»
2. Завдання видано студенту Данііл ГАРКАВІЮК
(прізвище, ім'я, по батькові)
3. Керівник роботи професор кафедри КН Едуард МАНЗІЮК
(прізвище, ім'я, по батькові)
4. Затверджені наказом університету від « 26 » 08 2024 р. № 60 .
5. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Мета кваліфікаційної роботи магістра полягає у підвищенні точності виявлення пухлин мозку на МРТ-зображеннях шляхом використання методів трансферного навчання. Для досягнення поставленої мети визначені наступні задачі: дослідити та проаналізувати існуючі методи виявлення пухлин мозку на основі глибокого навчання; розробити метод сегментації та класифікації пухлин мозку з використанням трансферного навчання; створити інформаційну технологію обробки та аналізу МРТ-зображень; провести експериментальне дослідження ефективності запропонованого методу.

Результатом виконання кваліфікаційної роботи магістра є розроблений метод сегментації та класифікації пухлин мозку з використанням трансферного навчання.

Ключові слова: МРТ, пухлини мозку, сегментація, трансферне навчання, глибоке навчання, автоматизація

Реферат

Кваліфікаційна робота магістра присвячена розробці методу виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами.

Актуальність теми. Актуальність роботи полягає в критичній необхідності розробки методів автоматизованого виявлення пухлин мозку на МРТ-зображеннях із використанням сучасних нейромережових технологій. Ручна сегментація та аналіз зображень, які традиційно виконуються радіологами, є трудомісткими, потребують значного часу, схильні до суб'єктивних помилок і часто залежать від рівня кваліфікації спеціаліста.

Сучасні досягнення у галузі штучного інтелекту, зокрема в глибокому навчанні, дозволяють значно покращити якість і швидкість діагностики, автоматизуючи процеси і забезпечуючи високу точність виявлення пухлин. Це сприятиме ранньому виявленню захворювань, підвищенню ефективності лікування, зменшенню витрат і покращенню загальних результатів для пацієнтів.

Окрім того, впровадження трансферного навчання допомагає подолати обмеження, пов'язані з нестачею розмічених медичних даних, що є типовою проблемою в медичній сфері. Це підкреслює актуальність роботи як для медичної практики, так і для наукових досліджень у галузі застосування нейромережових підходів до аналізу медичних зображень.

Мета роботи Мета роботи полягає у підвищенні точності виявлення та класифікації пухлин мозку на МРТ-зображеннях шляхом розробки методу з використанням трансферного навчання.

Об'єкт дослідження – процес виявлення та класифікації пухлин мозку на МРТ-зображеннях.

Предмет дослідження – моделі, методи та засоби виявлення пухлин мозку на МРТ-зображеннях з використанням трансферного навчання.

Методи дослідження. Застосовано нейронні мережі, методи нормалізації, фільтрування, аугментації, експериментальне тестування на реальних наборах даних.

Наукова новизна одержаних результатів. Удосконалено метод виявлення та класифікації пухлин мозку на МРТ-зображеннях, який відрізняється від існуючих використанням трансферного навчання з модифікованими верхніми шарами, включаючи додаткову згорткову основу та повністю з'єднаний шар, що дозволило покращити точність класифікації на МРТ-зображеннях.

Апробація результатів кваліфікаційної роботи магістра та публікації. Гаркавюк Д.С., Петровський С.С., Вознюк Л.О. Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами. Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2024». - Хмельницький, 2024. - С.140 - 142

Структура та обсяг роботи. Робота містить вступ, чотири розділи, висновки, списку використаних джерел та додатків. Обсяг основного тексту – 86 сторінок, включаючи 17 рисунків, 1 таблиця та 44 джерела у списку літератури.

Ключові слова: МРТ, пухлини мозку, нейронні мережі, трансферне навчання, сегментація, медичні зображення, автоматизація, діагностика.

Зміст

Перелік скорочень	4
Вступ.....	5
РОЗДІЛ 1 Аналіз предметної області та методів виявлення пухлин мозку на зображеннях	7
1.1 Огляд предметної області.....	7
1.2 Аналіз методів машинного навчання для роботи із зображеннями	10
1.3 Особливості застосування штучного інтелекту для задач виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами	16
1.4 Мета та постановка задачі.....	20
РОЗДІЛ 2 Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами	22
2.1 Методика виокремлення структур	22
2.2 Виділення об'єктів на зображеннях.....	23
2.3 Застосування нейронної мережі з підвищеною точністю.....	24
2.4. Підхід до навчання нейромереж з використанням диференційованого навчання	26
2.5 Структура методу виявлення пухлин мозку на зображеннях МРТ	27
2.6 Структура методу виявлення пухлин із застосуванням трансферного навчання	36
2.7 Формування базової моделі у класифікації зображень.....	38
Висновки до розділу 2	41
РОЗДІЛ 3 Архітектура методу виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами.....	42
3.1 Загальна архітектура методу.....	42
3.2 Попередня обробка та підготовка МРТ-зображень.....	44
3.3 Алгоритм попередньої обробки зображень.....	45
3.4 Модифікована архітектура нейронної мережі	47
3.5 Реалізація трансферного навчання	49
3.6 Метрики визначення якості розробленого методу	52
Висновки до розділу 3	54

РОЗДІЛ 4 Експериментальні дослідження ефективності методу виявлення пухлин мозку на зображеннях МРТ.....	56
4.1 Опис набору даних та умов проведення експериментів.....	56
4.2 Методика проведення експериментальних досліджень.....	63
4.3 Параметри навчання моделей.....	65
4.4 Методи аугментації даних.....	66
4.5 Результати експериментальних досліджень.....	67
Висновки до розділу 4.....	78
Загальні висновки.....	80
Перелік посилань.....	81
Додатки	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
МРТ	Магнітно-резонансна томографія
ШІ	Штучний інтелект
МН	Машинне навчання
CNN	Convolutional neural network (Згорткова нейронна мережа)
XAI	Explainable artificial intelligence (Пояснювальний штучний інтелект)

Вступ

Актуальність теми. Актуальність роботи полягає в критичній необхідності розробки методів автоматизованого виявлення пухлин мозку на МРТ-зображеннях із використанням сучасних нейромережових технологій. Ручна сегментація та аналіз зображень, які традиційно виконуються радіологами, є трудомісткими, потребують значного часу, схильні до суб'єктивних помилок і часто залежать від рівня кваліфікації спеціаліста.

Сучасні досягнення у галузі штучного інтелекту, зокрема в глибокому навчанні, дозволяють значно покращити якість і швидкість діагностики, автоматизуючи процеси і забезпечуючи високу точність виявлення пухлин. Це сприятиме ранньому виявленню захворювань, підвищенню ефективності лікування, зменшенню витрат і покращенню загальних результатів для пацієнтів.

Окрім того, впровадження трансферного навчання допомагає подолати обмеження, пов'язані з нестачею розмічених медичних даних, що є типовою проблемою в медичній сфері. Це підкреслює актуальність роботи як для медичної практики, так і для наукових досліджень у галузі застосування нейромережових підходів до аналізу медичних зображень.

Мета роботи Мета роботи полягає у підвищенні точності виявлення та класифікації пухлин мозку на МРТ-зображеннях шляхом розробки методу з використанням трансферного навчання.

Об'єкт дослідження – процес виявлення та класифікації пухлин мозку на МРТ-зображеннях.

Предмет дослідження – моделі, методи та засоби виявлення пухлин мозку на МРТ-зображеннях з використанням трансферного навчання.

Методи дослідження. Застосовано нейронні мережі, методи нормалізації, фільтрування аугментації, експериментальне тестування на реальних наборах даних.

Наукова новизна одержаних результатів. Удосконалено метод виявлення та класифікації пухлин мозку на МРТ-зображеннях, який відрізняється від існуючих використанням трансферного навчання з модифікованими верхніми шарами,

включаючи додаткову згорткову основу та повністю з'єднаний шар, що дозволило покращити точність класифікації на МРТ-зображеннях.

Апробація результатів кваліфікаційної роботи магістра та публікації.

Гаркавюк Д.С., Петровський С.С., Вознюк Л.О. Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами. Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2024». - Хмельницький, 2024. - С.140 - 142

Структура та обсяг роботи. Робота містить вступ, чотири розділи, висновки, списку використаних джерел та додатків. Обсяг роботи – 86 сторінок, включаючи 17 рисунків, 1 таблиця та 44 джерела у списку літератури.

РОЗДІЛ 1 Аналіз предметної області та методів виявлення пухлин мозку на зображеннях

1.1 Огляд предметної області

Виявлення та сегментація пухлин мозку на зображеннях магнітно-резонансної томографії (МРТ) є критично важливим завданням у нейрохірургії та неврології. Точна і своєчасна діагностика відіграє ключову роль у плануванні лікування та прогнозуванні результатів для пацієнтів. Традиційно, цей процес виконувався вручну кваліфікованими радіологами, що вимагало значних витрат часу та було схильне до суб'єктивності. З розвитком технологій штучного інтелекту, зокрема глибокого навчання, з'явилися нові можливості для автоматизації та покращення цього процесу [1–3].

Згорткові нейронні мережі стали основою багатьох сучасних методів сегментації пухлин мозку. Вони здатні автоматично вивчати ієрархію ознак з МРТ-зображень, що дозволяє ефективно виявляти та сегментувати різні типи пухлин. Було продемонстровано в дослідженні високу ефективність CNN (Convolutional neural network) у сегментації пухлин мозку, досягнувши точності, порівнянної з експертною оцінкою [4].

Проте, навчання ефективних моделей глибокого навчання вимагає великих обсягів розмічених даних, що часто є проблемою у медичній галузі. Для подолання цього обмеження були розроблені методи трансферного навчання та аугментації даних. Автори показали, як ці підходи можуть значно покращити швидкодію моделей при обмежених наборах даних [5–7].

Ансамблеві методи, які комбінують декілька моделей, виявилися ефективним підходом для підвищення надійності та точності сегментації. Розроблено ансамбль з множинних моделей та архітектур, що дозволило подолати обмеження окремих моделей та досягти вищої точності сегментації [8, 9].

Важливим напрямком досліджень є розробка 3D-CNN, які здатні аналізувати повний об'єм МРТ-зображень, а не окремі зрізи. Це дозволяє враховувати

просторові залежності між зрізами та покращувати точність сегментації складних структур пухлин. Запропоновано інноваційний підхід, який поєднує 3D-сегментацію з варіаційним автоенкодером для покращення якості сегментації [9, 10].

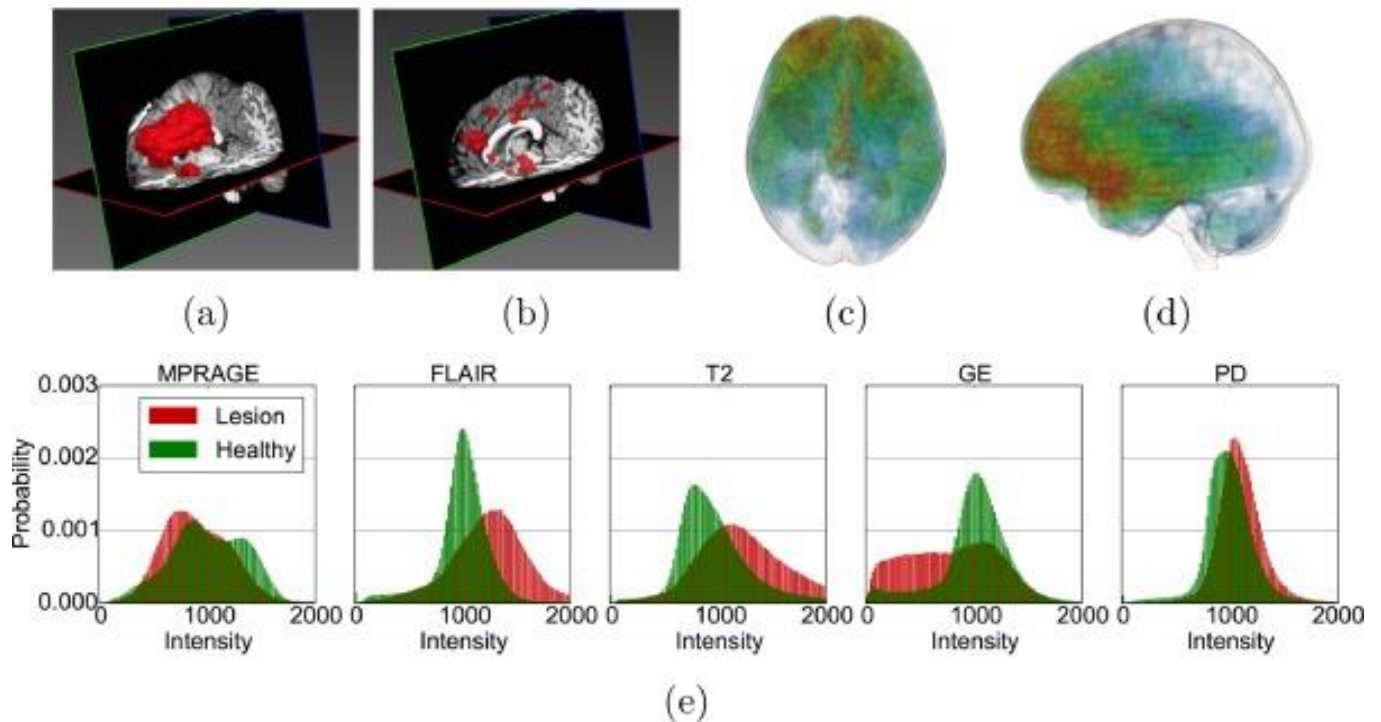


Рисунок 1.1 – Гетерогенний вигляд уражень [9]

Мультимодальні підходи, які використовують різні послідовності МРТ, стали важливим напрямком досліджень. Вони дозволяють отримати більш повну інформацію про структуру та характеристики пухлин. Розроблено інтегровану модель глибокого навчання для одночасної сегментації та класифікації пухлин мозку, використовуючи мультимодальні дані [11–13].

Останнім часом зростає увага до інтерпретованості моделей глибокого навчання. Це особливо важливо в медичному контексті, де розуміння процесу прийняття рішень моделлю є критичним для довіри лікарів та впровадження в клінічну практику. Тому було зроблено кроки у цьому напрямку, розробляючи моделі, які не тільки точно сегментують пухлини, але й надають певне пояснення своїх рішень [13, 14].

Незважаючи на значний прогрес, залишаються важливі виклики, такі як стандартизація методів оцінки, інтеграція в клінічну практику та забезпечення надійності моделей для різноманітних клінічних випадків. Майбутні дослідження, ймовірно, зосередяться на розробці більш узагальнених моделей, здатних працювати з різними типами пухлин та модальностями зображень, а також на подальшому покращенні інтерпретованості моделей.

Використання нейромережових методів для виявлення пухлин мозку на МРТ-зображеннях демонструє великий подальший успіх для покращення діагностики та лікування хворих. Подальший прогрес у цій галузі повинен значно позитивно вплинути на якість медичної допомоги та результати лікування хворих з пухлинами мозку.

Важливим аспектом дослідження у галузі виявлення пухлин мозку є розробка методів, здатних працювати з обмеженими наборами даних. Це особливо актуально для рідкісних типів пухлин або специфічних клінічних випадків, де отримання великих обсягів розмічених даних є проблематичним. У цьому контексті, методи слабконаглядового та самонаглядового навчання набувають все більшого значення. Запропоновано інноваційний підхід, який використовує обмежену кількість повністю розмічених зображень разом з більшою кількістю частково розмічених даних для покращення точності сегментації [15–17].

Інтеграція експертних знань у процес навчання моделей є ще одним перспективним напрямком досліджень. Розроблено метод, який дозволяє включати експертні знання про анатомію мозку та характеристики пухлин у архітектуру нейронної мережі. Це не тільки покращує точність сегментації, але й робить модель більш інтерпретованою для медичних фахівців [11, 18–20].

Важливим аспектом є також оцінка надійності та невизначеності прогнозів моделей. У медичному контексті, де помилки можуть мати серйозні наслідки, здатність моделі оцінювати впевненість у своїх прогнозах є критично важливою. Недавні дослідження запропонували методи для оцінки невизначеності в глибоких нейронних мережах, які можуть бути застосовані до задачі сегментації пухлин мозку [21].

Розвиток методів федеративного навчання відкриває нові можливості для співпраці між медичними закладами без необхідності обміну конфіденційними даними пацієнтів. Це особливо важливо в контексті медичних досліджень, де захист приватності пацієнтів є першочерговим завданням. Автори продемонстрували потенціал федеративного навчання для покращення сегментації пухлин мозку шляхом об'єднання знань з різних установ без обміну вихідними даними [22, 23].

Використання методів пояснюваного штучного інтелекту стає все більш важливим для прийняття нейромережевих технологій у клінічній практиці. Ці методи дозволяють візуалізувати та інтерпретувати рішення моделей, що критично важливо для довіри лікарів до автоматизованих систем діагностики. Запропоновано кілька підходів до пояснення рішень моделей глибокого навчання в контексті медичної візуалізації [24, 25].

Інтеграція різних модальностей зображень, таких як МРТ, КТ та ПЕТ, є перспективним напрямком для покращення діагностики пухлин мозку. Кожна модальність надає унікальну інформацію про структуру та функціонування мозку, і їх комбінація може значно підвищити точність діагностики. Використовуючи цей підхід розроблено мультимодальну модель глибокого навчання, яка ефективно комбінує інформацію з різних типів зображень для покращення сегментації та класифікації пухлин мозку [24, 26].

1.2 Аналіз методів машинного навчання для роботи із зображеннями

Методи машинного навчання для роботи із зображеннями, особливо в контексті виявлення та сегментації пухлин мозку, зазнали значного розвитку протягом останніх років. Ця еволюція характеризується переходом від класичних методів комп'ютерного зору до сучасних підходів глибокого навчання.

Традиційні методи машинного навчання, такі як метод опорних векторів та випадкові ліси, тривалий час були основними інструментами для аналізу медичних зображень. Ці методи базувалися на ручному виділенні ознак, що вимагало значних експертних знань та часто було недостатньо ефективним для складних завдань,

таких як сегментація пухлин мозку. Незважаючи на це, вони заклали важливу основу для розуміння проблеми та розробки більш складних методів.

Прорив у галузі глибокого навчання, зокрема поява згорткових нейронних мереж, революціонував підхід до аналізу медичних зображень. CNN здатні автоматично вивчати ієрархію ознак безпосередньо з вихідних даних, що дозволяє їм ефективно виявляти складні патерни на зображеннях МРТ [5, 27]. Архітектура U-Net, яка стала особливо популярною для задач сегментації медичних зображень завдяки її здатності зберігати просторову інформацію при сегментації, була успішно застосована для виявлення пухлин мозку [28–30].

Згорткові нейронні мережі здійснили революцію в аналізі медичних зображень завдяки їх здатності автоматично вивчати ієрархічні ознаки безпосередньо з вихідних даних. Це дозволяє CNN ефективно виявляти складні патерни на зображеннях МРТ, що значно підвищує точність діагностики. Однією з ключових переваг CNN у цій галузі є автоматичне видалення ознак, що зменшує потребу в ручному виборі характеристик експертами. Крім того, ієрархічне навчання дозволяє мережі вивчати ознаки різних рівнів абстракції, починаючи від простих елементів, таких як краї та текстури, і закінчуючи складними структурами, характерними для пухлин.

Важливою особливістю CNN є їх просторова інваріантність, тобто здатність розпізнавати об'єкти незалежно від їх положення на зображенні, що особливо важливо при аналізі медичних знімків, де патології можуть з'являтися в різних частинах органу. Ця властивість робить CNN надзвичайно ефективними для виявлення аномалій на МРТ-зображеннях мозку.

Архітектура U-Net, яка стала особливо популярною для задач сегментації медичних зображень, відзначається своєю здатністю зберігати просторову інформацію при сегментації. Ця особливість робить U-Net надзвичайно ефективною для точного визначення меж пухлин мозку на МРТ-зображеннях. U-Net складається з шляху стиснення (енкодер) та шляху розширення (декодер) з прямими з'єднаннями між відповідними шарами, що дозволяє мережі зберігати детальну просторову інформацію при відновленні сегментованого зображення.

Застосування U-Net для виявлення пухлин мозку показало вражаючі результати, дозволяючи точно окреслювати межі пухлин різних розмірів та форм. Ця архітектура здатна ефективно працювати навіть з обмеженою кількістю навчальних даних, що особливо важливо в медичній галузі, де отримання великих анотованих наборів даних може бути складним завданням.

Успіх CNN та U-Net у виявленні пухлин мозку відкрив нові можливості для ранньої діагностики та планування лікування. Ці технології дозволяють не лише виявляти наявність пухлини, але й точно визначати її розмір, форму та розташування, що критично важливо для планування хірургічних втручань та оцінки ефективності лікування.

Розвиток архітектур глибокого навчання призвів до створення більш складних моделей, таких як ResNet та DenseNet, які дозволяють навчати дуже глибокі мережі без проблем зникаючого градієнта [31]. Ці архітектури були успішно адаптовані для задач сегментації пухлин мозку, демонструючи значне покращення точності порівняно з попередніми підходами.

Важливим напрямком розвитку стало створення 3D-CNN, які здатні обробляти повний об'єм МРТ-зображень, а не окремі зрізи. Це дозволяє враховувати просторові залежності між зрізами і покращувати точність сегментації складних структур пухлин. Авторами запропоновано інноваційний підхід, який поєднує 3D-сегментацію з варіаційним автоенкодером для покращення якості сегментації [10].

Методи трансферного навчання стали важливим інструментом для подолання проблеми обмежених наборів даних у медичній візуалізації. Вони дозволяють використовувати знання, отримані при навчанні на великих наборах даних загального призначення, для покращення продуктивності на специфічних медичних завданнях [5, 32, 33].

Генеративні змагальні мережі відкрили нові можливості для аугментації даних та синтезу реалістичних медичних зображень. Це особливо корисно для розширення обмежених наборів даних та покращення узагальнюючої здатності моделей [23, 34].

Ансамблеві методи, які комбінують прогнози кількох моделей, показали високу ефективність у підвищенні точності та надійності сегментації пухлин мозку. Kamnitsas et al. продемонстрували, що ансамбль різних архітектур CNN може значно покращити результати сегментації порівняно з окремими моделями [8].

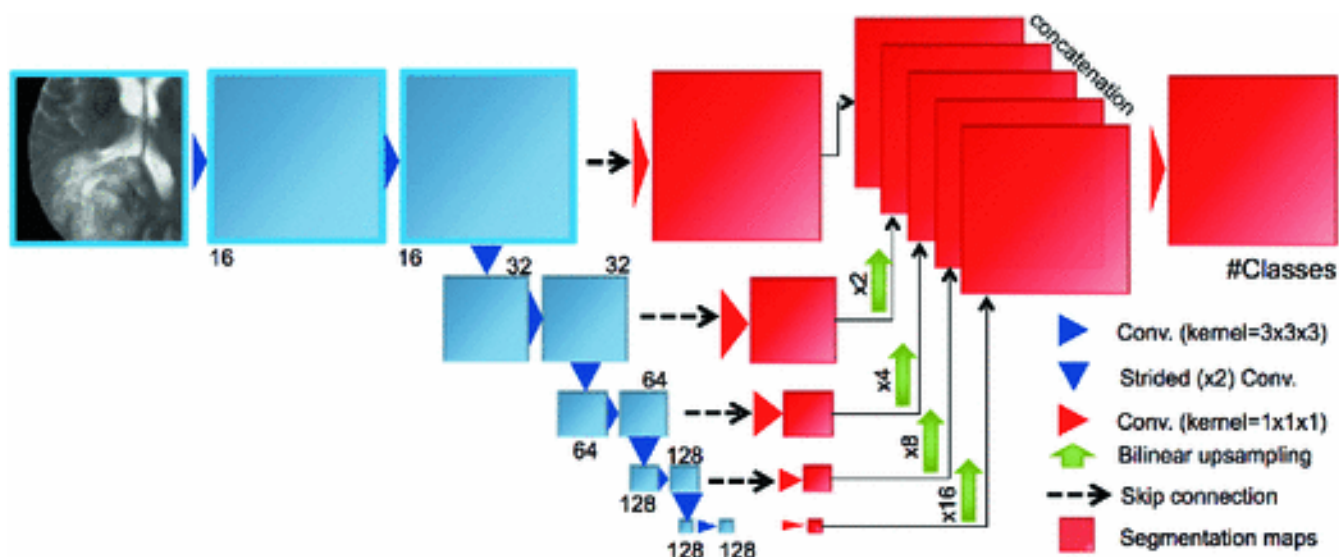


Рисунок 1.2 – Ансамблі з декількох моделей та архітектур для сегментації пухлин головного мозку [8].

Методи активного навчання набувають все більшого значення в контексті обмежених розмічених даних. Вони дозволяють ефективно використовувати великі обсяги нерозмічених даних разом з обмеженою кількістю розмічених зразків. Розвиток методів інтерпретованого машинного навчання став критично важливим для прийняття цих технологій у клінічній практиці. Методи, які дозволяють візуалізувати та пояснювати рішення моделей глибокого навчання, підвищують довіру лікарів до автоматизованих систем діагностики.

Незважаючи на значний прогрес, залишаються важливі виклики, такі як робота з незбалансованими даними, обробка зображень з різних сканерів та протоколів, а також інтеграція різних модальностей зображень. Подальші дослідження, ймовірно, будуть зосереджені на розробці більш узагальнених та інтерпретованих моделей, здатних ефективно працювати в різноманітних клінічних умовах.

Важливим аспектом розвитку методів машинного навчання для роботи з медичними зображеннями є адаптація до різноманітності та варіабельності даних. Запропоновано метод, який використовує адаптивну нормалізацію для покращення генералізації моделей на зображеннях з різних джерел та протоколів сканування [12, 13]. Це особливо важливо для створення надійних систем, здатних працювати в різних клінічних умовах.

Інтеграція експертних знань у процес навчання моделей стала ще одним перспективним напрямком. Розроблено підхід, який дозволяє включати анатомічні обмеження та експертні знання про структуру пухлин у архітектуру нейронної мережі [35]. Це не тільки покращує точність сегментації, але й робить модель більш інтерпретованою для медичних фахівців.

Методи навчання з підкріпленням також знаходять застосування в аналізі медичних зображень. Продемонстровано ефективність цих методів для навігації та локалізації анатомічних структур на МРТ-зображеннях [36]. Це відкриває нові можливості для автоматизації процесу діагностики та зменшення навантаження на радіологів.

Розвиток методів федеративного навчання став важливим кроком у подоланні проблем приватності та обмеженого доступу до даних. Запропоновано підхід, який дозволяє навчати моделі на розподілених наборах даних без необхідності централізованого зберігання чутливої інформації пацієнтів [37]. Це відкриває нові можливості для співпраці між медичними закладами та покращення якості моделей.

Використання методів мета-навчання (meta-learning) дозволяє створювати більш адаптивні моделі, здатні швидко налаштовуватися на нові завдання або типи даних. Використання такого підходу дозволило продемонструвати ефективність цього підходу для сегментації пухлин мозку в умовах обмежених даних [38]. Це особливо важливо для рідкісних типів пухлин або специфічних клінічних випадків.

Інтеграція різних модальностей зображень, таких як МРТ, КТ та ПЕТ, залишається актуальним напрямком досліджень. Розроблено мультимодальну модель глибокого навчання, яка ефективно комбінує інформацію з різних типів

зображень для покращення сегментації та класифікації пухлин мозку [26]. Це дозволяє отримати більш повну картину патології та підвищити точність діагностики.

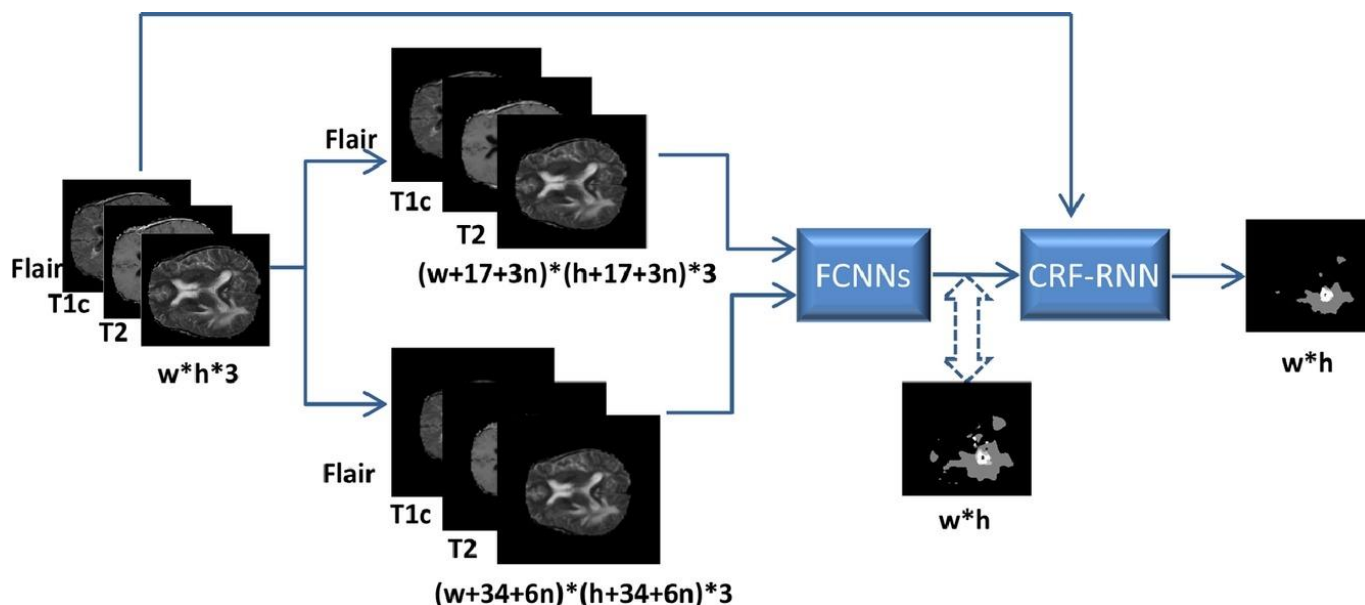


Рисунок 1.3 – Модель глибокого навчання, що інтегрує FCNN та CRF для сегментації пухлин головного мозку [13]

Розробка методів оцінки невизначеності прогнозів моделей стала важливим аспектом для клінічного застосування. Запропоновано підхід для оцінки алеаторної та епістемічної невизначеності в глибоких нейронних мережах [21]. Це дозволяє моделям не тільки робити прогнози, але й оцінювати рівень впевненості в цих прогнозах, що критично важливо для прийняття клінічних рішень.

Використання самонавчальних (self-supervised) методів набуває все більшого значення для ефективного використання великих обсягів нерозмічених даних. Запропоновано метод навчання для покращення якості ознак, що вивчаються моделлю без використання розмічених даних [32, 39]. Це відкриває нові можливості для попереднього навчання моделей на великих наборах нерозмічених медичних зображень.

Незважаючи на значний прогрес, залишаються важливі виклики, такі як інтерпретованість складних моделей, робота з рідкісними патологіями та адаптація

до постійно змінюваних умов клінічної практики. Подальші дослідження, ймовірно, будуть зосереджені на розробці більш надійних, адаптивних та інтерпретованих моделей, здатних ефективно працювати в реальних клінічних умовах та інтегруватися в існуючі системи охорони здоров'я.

1.3 Особливості застосування штучного інтелекту для задач виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами

Застосування штучного інтелекту, зокрема нейромережових методів, для виявлення пухлин мозку на зображеннях МРТ характеризується рядом унікальних особливостей, які відрізняють цю галузь від інших областей комп'ютерного зору.

Однією з ключових особливостей є складність та різноманітність даних МРТ-зображень мозку. Пухлини можуть значно відрізнятися за розміром, формою та локалізацією, а різні типи МРТ-последовностей надають унікальну інформацію. Запропонували мультимодальний підхід, який ефективно комбінує інформацію з різних МРТ-последовностей для покращення точності сегментації пухлин.

На відміну від багатьох задач комп'ютерного зору, де доступні мільйони розмічених зображень, в медичній галузі кількість якісно розмічених даних часто обмежена. Це створює унікальні виклики для навчання глибоких нейронних мереж. Розроблено метод самонавчання, який дозволяє ефективно використовувати нерозмічені дані для покращення якості сегментації пухлин мозку [19].

У медичному контексті помилки можуть мати серйозні наслідки, тому вимоги до точності моделей особливо високі. Автори запропонували архітектуру nnU-Net, яка автоматично адаптується до конкретної задачі сегментації і досягає високої точності на різних наборах медичних даних, включаючи сегментацію пухлин мозку [28]. Кожна синя клітинка відповідає багатоканальній функціональній карті. Кількість каналів позначено на верхній частині квадратика (рис. 1.4).

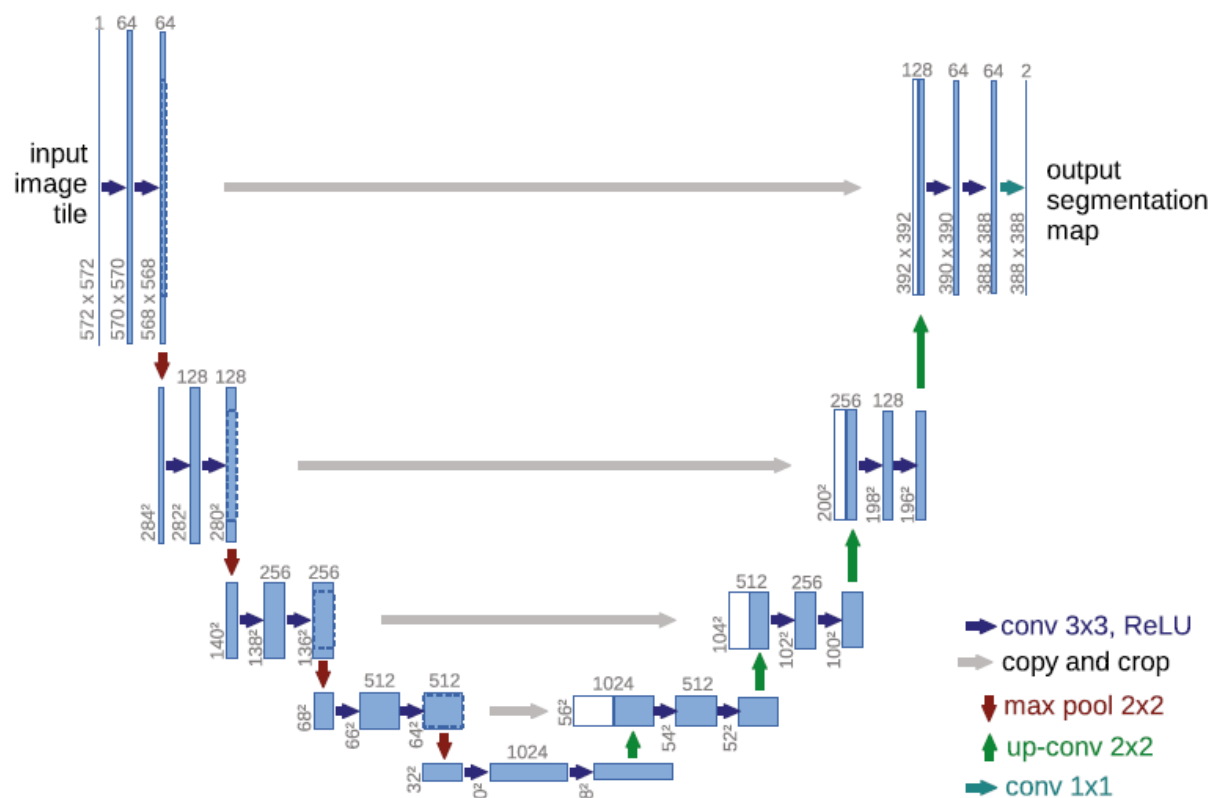


Рисунок 1.4 – Архітектура U-net (приклад для 32x32 пікселів у найнижчій роздільній здатності) [28]

Для прийняття неймережевих методів у клінічній практиці критично важливо, щоб рішення моделей були інтерпретовані лікарями. Представлено огляд методів інтерпретації глибоких нейронних мереж у контексті аналізу медичних зображень, включаючи виявлення пухлин мозку [40].

МРТ-зображення мозку є тривимірними, що вимагає спеціальних підходів до їх обробки. Автори розробили 3D архітектуру, яка ефективно обробляє повний об'єм МРТ-зображень для сегментації пухлин мозку [10].

У більшості випадків об'єм здорової тканини значно перевищує об'єм пухлини, що створює проблему незбалансованості класів. Запропонували спеціальну функцію втрат, яка ефективно вирішує цю проблему при сегментації пухлин мозку [26].

Зображення МРТ можуть значно відрізнятися залежно від використаного обладнання та протоколів сканування. Розробили метод доменної адаптації, який дозволяє моделям ефективно працювати з зображеннями з різних джерел [8].

У клінічних умовах важлива не тільки точність, але й швидкість обробки зображень. Запропоновано легку архітектуру CNN, яка забезпечує швидку та точну сегментацію пухлин мозку на обмежених обчислювальних ресурсах [24].

Для ефективного використання в реальних умовах, нейромережеві методи повинні бути інтегровані з існуючими клінічними системами. Представлено підхід до інтеграції глибоких нейронних мереж у клінічні системи підтримки прийняття рішень для діагностики пухлин мозку.

У медичному контексті важливо не тільки отримати прогноз, але й оцінити його надійність. Тому розроблено метод для оцінки невизначеності прогнозів при сегментації пухлин мозку, що дозволяє виявляти складні або неоднозначні випадки [41].

Ці особливості створюють унікальні виклики та можливості для застосування нейромережевих методів у задачах виявлення пухлин мозку на зображеннях МРТ, стимулюючи розробку інноваційних підходів та архітектур. Подальший розвиток цієї галузі потребує міждисциплінарної співпраці між спеціалістами з машинного навчання, радіології та нейрохірургії для створення надійних та ефективних систем, здатних покращити діагностику та лікування пухлин мозку.

Продовжуючи огляд особливостей застосування штучного інтелекту для виявлення пухлин мозку на зображеннях МРТ, варто зазначити, що ця галузь постійно розвивається, адаптуючись до нових викликів та можливостей.

Однією з важливих тенденцій є розробка методів, здатних працювати з обмеженою кількістю розмічених даних. Це особливо актуально для рідкісних типів пухлин або специфічних клінічних випадків. У цьому контексті, запропоновано підхід на основі активного навчання, який дозволяє ефективно вибирати найбільш інформативні зразки для розмітки, тим самим оптимізуючи процес збору даних та навчання моделей [42].

Інтеграція експертних знань у процес навчання нейронних мереж стає все більш важливою. Розроблено метод, який дозволяє включати анатомічні обмеження та експертні знання про структуру пухлин у архітектуру нейронної мережі. Це не тільки покращує точність сегментації, але й робить модель більш інтерпретованою для медичних фахівців [23].

Розвиток методів федеративного навчання відкриває нові можливості для співпраці між медичними закладами без необхідності обміну конфіденційними даними пацієнтів. Продемонстровано потенціал федеративного навчання для покращення сегментації пухлин мозку шляхом об'єднання знань з різних установ без обміну вихідними даними.

Важливим аспектом є також розробка методів, здатних адаптуватися до змін у розподілі даних. Це особливо актуально, враховуючи постійний розвиток технологій МРТ та можливі зміни в протоколах сканування. Запропоновано метод безперервного навчання, який дозволяє моделям адаптуватися до нових даних без забування раніше вивченої інформації [39].

Використання методів пояснюваного штучного інтелекту (ХАІ) стає все більш важливим для прийняття нейромережових технологій у клінічній практиці. Розроблено підхід, який дозволяє візуалізувати та інтерпретувати рішення моделей глибокого навчання при сегментації пухлин мозку, що підвищує довіру лікарів до автоматизованих систем діагностики [25].

Інтеграція різних модальностей зображень, таких як МРТ, КТ та ПЕТ, є перспективним напрямком для покращення діагностики пухлин мозку. Запропонували мультимодальну архітектуру, яка ефективно комбінує інформацію з різних типів зображень для підвищення точності виявлення та характеристики пухлин.

Розробка методів для роботи з незбалансованими даними залишається актуальною проблемою. Автори представили новий підхід до вирішення проблеми незбалансованості класів при сегментації пухлин мозку, використовуючи комбінацію спеціалізованих функцій втрат та методів аугментації даних.

Важливим напрямком є також розробка методів для оцінки невизначеності прогнозів моделей. Це особливо важливо в клінічному контексті, де розуміння рівня впевненості моделі в її прогнозах може бути критичним для прийняття рішень. Запропоновано байєсівський підхід до оцінки невизначеності при сегментації медичних зображень, включаючи МРТ-зображення мозку [43].

Важливо відзначити зростаючу роль міждисциплінарних досліджень у цій галузі. Співпраця між спеціалістами з машинного навчання, радіології, нейрохірургії та інших суміжних дисциплін стає все більш важливою для розробки ефективних та клінічно релевантних рішень. Автори продемонстрували потенціал такої співпраці, розробивши систему підтримки прийняття рішень на основі глибокого навчання для персоналізованого лікування гліобластоми [44].

Ці тенденції та розробки демонструють динамічний характер застосування штучного інтелекту для виявлення пухлин мозку на зображеннях МРТ. Подальший прогрес у цій галузі має потенціал значно покращити діагностику та лікування пухлин мозку, підвищуючи якість медичної допомоги та результати лікування хворих.

1.4 Мета та постановка задачі

Відповідно до проведеного аналізу сформулювало мету та задачі дослідження.

Мета роботи полягає у підвищенні точності виявлення та класифікації пухлин мозку на МРТ-зображеннях шляхом розробки методу з використанням трансферного навчання.

Задачі дослідження:

- провести аналіз існуючих методів та підходів до виявлення пухлин мозку на МРТ-зображеннях з використанням методів машинного та глибокого навчання;
- розробити метод виявлення та класифікації пухлин мозку з використанням трансферного навчання на основі архітектури моделей глибокого навчання;

- реалізувати попередню обробку та аугментацію МРТ-зображень для покращення якості навчальних даних;
- провести експериментальне дослідження ефективності спроектованого методу шляхом порівняння різних архітектур та оцінки їх точності класифікації пухлин мозку.

РОЗДІЛ 2 Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами

2.1 Методика виокремлення структур

Критичним етапом аналізу МРТ-зображень мозку є відділення нейронних тканин від оточуючих структур. Новітній метод вирішує це завдання, інтегруючи просторове зіставлення, класифікацію тканин та геометричні трансформації. На відміну від попередніх технік, цей підхід зберігає детальну топографію поверхні кори, включаючи її межу з ліквором.

Застосуємо метод, який розглядає нейронну тканину як єдиний комплекс, де сіра та біла речовина утворюють суцільну структуру. В межах цієї структури можна простежити неперервні шляхи між будь-якими точками, де інтенсивність сигналу монотонно не зростає. Це можна уявити як топографічну карту, де нейронна тканина формує височини та плато, оточені низинами тканинами.

Алгоритм починається з узгодження досліджуваного зображення з набором анатомічних шаблонів. Паралельно проводиться автоматична класифікація тканин усього об'єму голови. Результати цих процесів комбінуються для створення початкової маски мозку.

Далі відбувається покрокове уточнення цієї маски. Спочатку видаляються дрібні ізольовані фрагменти та заповнюються невеликі порожнини. Потім маска поступово розширюється, слідуючи градієнтам інтенсивності та враховуючи ймовірнісні оцінки приналежності до різних типів тканин. Це дозволяє точно окреслити межу кори, зберігаючи тонкий шар ліквору навколо неї.

Такий комплексний підхід забезпечує надійне відокремлення мозкових структур від оточуючих тканин, зберігаючи при цьому їх точну морфологію. Це створює оптимальну основу для подальшого аналізу нейровізуалізаційних даних.

2.2 Виділення об'єктів на зображеннях

Метод жадного алгоритма представляє собою сучасний підхід у галузі комп'ютерного зору, пропонуючи спосіб відокремлення об'єктів від фону. Унікальність цього алгоритму полягає в його здатності ефективно працювати навіть при незначній різниці в кольорових характеристиках об'єкта та навколишнього середовища.

В основі жадного алгоритма лежить вдосконалена теорія графів, доповнена двома ключовими інноваціями. Перша - це циклічне уточнення результатів, а друга - можливість працювати з неповною вхідною інформацією. Ці нововведення радикально спрощують процес взаємодії з користувачем.

Для початку роботи алгоритму достатньо, щоб користувач приблизно окреслив область інтересу прямокутником. Ця дія автоматично надає системі базову інформацію про розташування об'єкта та фону, усуваючи необхідність у детальному ручному маркуванні.

Жадний алгоритм також вирізняється своїм підходом до обробки граничних областей об'єкта. Вбудований механізм розрахунку прозорості забезпечує плавний перехід між об'єктом та фоном, мінімізуючи візуальні дефекти по контуру виділення.

Технічно алгоритм оперує складною мережею взаємопов'язаних елементів, де кожна точка зображення представлена як вузол у графі. Ці вузли утворюють зв'язки з сусідніми точками та спеціальними вузлами, що представляють передній план та фон. Процес сегментації здійснюється шляхом аналізу та розділення цієї мережі.

Особливу роль у роботі алгоритму відіграє система оцінки зв'язків між елементами графа. Для цього жадний алгоритм застосовує складні статистичні моделі, які адаптуються до кольорових характеристик конкретного зображення.

Процес виділення об'єкта відбувається поетапно. На кожному кроці алгоритм уточнює свої припущення щодо належності кожної точки до об'єкта чи фону, постійно покращуючи якість сегментації.

Завдяки такому підходу, жадний алгоритм дозволяє досягти високої точності виділення об'єктів навіть на складних зображеннях, мінімізуючи при цьому необхідність втручання користувача.

2.3 Застосування нейронної мережі з підвищеною точністю

Згорткові нейронні мережі здійснили переворот у сфері комп'ютерного зору. Ці передові алгоритми мають унікальну здатність автоматично виявляти та класифікувати ключові елементи зображень, імітуючи процеси обробки візуальної інформації в людському мозку.

Головна перевага CNN полягає у їх здатності самостійно визначати важливі ознаки зображень. На відміну від традиційних методів, де характеристики зображень визначалися вручну, CNN "навчаються" виявляти релевантні патерни самостійно. Це робить їх надзвичайно адаптивними до різноманітних типів візуальних даних.

Архітектура CNN складається з послідовності спеціалізованих шарів. Перші шари зазвичай фокусуються на базових елементах, таких як контури та кольорові переходи. З кожним наступним шаром мережа здатна розпізнавати все складніші структури, поступово формуючи комплексне розуміння вмісту зображення.

Ключовим елементом CNN є операція згортки. Цей процес дозволяє мережі ефективно аналізувати локальні ділянки зображення, виявляючи важливі особливості незалежно від їх розташування. Така властивість робить CNN особливо ефективними для задач, де важлива інваріантність до зсуву та масштабу.

Іншим важливим компонентом є шари об'єднання, які зменшують просторові розміри даних. Це не лише знижує обчислювальну складність, але й допомагає мережі фокусуватися на найбільш значущих ознаках, ігноруючи несуттєві деталі.

Фінальні шари CNN зазвичай представлені повнозв'язними нейронними мережами. Вони інтегрують інформацію з попередніх шарів для прийняття остаточного рішення щодо класифікації зображення.

Навчання CNN відбувається шляхом оптимізації великої кількості параметрів на основі великих наборів розмічених даних. Цей процес дозволяє мережі поступово покращувати свою здатність розрізняти та класифікувати об'єкти на зображеннях.

Завдяки своїй ефективності та адаптивності, CNN стали основою багатьох сучасних систем комп'ютерного зору, від розпізнавання облич до автономного водіння.

EfficientNet є новою розробкою у розвитку глибоких нейронних мереж. Ця архітектура вирішила ключову проблему, яка довго стримувала прогрес у цій галузі – деградацію точності при збільшенні глибини мережі.

Основна ідея EfficientNet полягає у впровадженні обхідних з'єднань. Ці з'єднання дозволяють сигналам пропускати один або кілька шарів, створюючи короткі шляхи для градієнтів. Такий підхід базується на припущенні, що додаткові шари не повинні погіршувати роботу мережі, оскільки завжди можна просто пропустити інформацію через ці шари без змін.

Ця концепція виявилася надзвичайно ефективною. EfficientNet дозволяє будувати значно глибші мережі, які при цьому легше навчаються і демонструють кращу продуктивність. Замість того, щоб напругу моделювати бажане відображення, шари EfficientNet навчаються представляти залишкову функцію, що виявилось більш ефективним підходом.

Хоча EfficientNet не був першою архітектурою, що використовувала обхідні з'єднання, він відрізняється своєю простотою та ефективністю. На відміну від більш складних підходів, Highway Networks, EfficientNet використовує прості, непараметризовані обхідні з'єднання, що виявилось ключем до його успіху.

Згодом архітектура EfficientNet була вдосконалена. Зокрема, було запропоновано варіант з попередньою активацією, який ще більше покращив проходження градієнтів через мережу. Це дозволило успішно навчати надглибокі мережі з сотнями шарів.

EfficientNet стала основою для багатьох сучасних архітектур комп'ютерного зору. Її принципи були адаптовані для різноманітних завдань, від класифікації зображень до сегментації об'єктів.

Успіх EfficientNet продемонстрував важливість ретельного проектування архітектури нейронних мереж. Він показав, що іноді прості ідеї, такі як забезпечення прямих шляхів для градієнтів, можуть мати величезний вплив на ефективність глибоких моделей.

2.4. Підхід до навчання нейромереж з використанням диференційованого навчання

Застосуємо нову стратегія оптимізації – диференційоване навчання шарів. Цей метод пропонує революційний підхід до налаштування нейронних мереж, особливо ефективний для складних, багат шарових архітектур.

Суть методу полягає у застосуванні різних швидкостей навчання для різних шарів мережі. Зазвичай, нижчі (початкові) шари отримують менші темпи навчання, тоді як вищі (кінцеві) шари навчаються швидше. Таке розподілення базується на глибокому розумінні ролі різних шарів у процесі обробки інформації.

Обґрунтування цього підходу лежить у природі інформації, яку обробляють різні шари. Нижні рівні мережі зазвичай відповідають за виявлення базових, універсальних ознак, які залишаються відносно стабільними для різних завдань. Натомість, верхні шари спеціалізуються на більш абстрактних, специфічних для конкретного завдання характеристиках.

Активація різних шарів мережі змінюється нелінійно від нижніх до верхніх рівнів. Верхні шари демонструють значно вищу активність і варіабельність порівняно з нижніми. Це спостереження підкріплює логіку диференційованого навчання.

Практична реалізація цього методу вимагає модифікації стандартного алгоритму стохастичного градієнтного спуску. Замість єдиної швидкості навчання для всієї мережі, кожен шар отримує свій власний коефіцієнт навчання. Це дозволяє точніше контролювати процес оптимізації на різних рівнях мережі.

Диференційоване навчання шарів виявилось особливо ефективним при тонкому налаштуванні попередньо навчених моделей для нових завдань. Воно

дозволяє зберегти цінні низькорівневі ознаки, одночасно адаптуючи вищі рівні до специфіки нового завдання.

Цей метод не тільки покращує точність моделей, але й часто прискорює процес збіжності навчання. Він дозволяє більш ефективно використовувати обчислювальні ресурси, фокусуючи зусилля на тих частинах мережі, які потребують найбільшого налаштування.

2.5 Структура методу виявлення пухлин мозку на зображеннях МРТ

Загальна структура методу виявлення пухлин мозку на зображеннях представлена на рисунку 2.1.

Етап попередньої обробки даних є фундаментальним для успішної роботи всього методу виявлення та класифікації пухлин мозку на МРТ-зображеннях. Він складається з декількох послідовних процесів, кожен з яких має важливе значення для кінцевого результату.

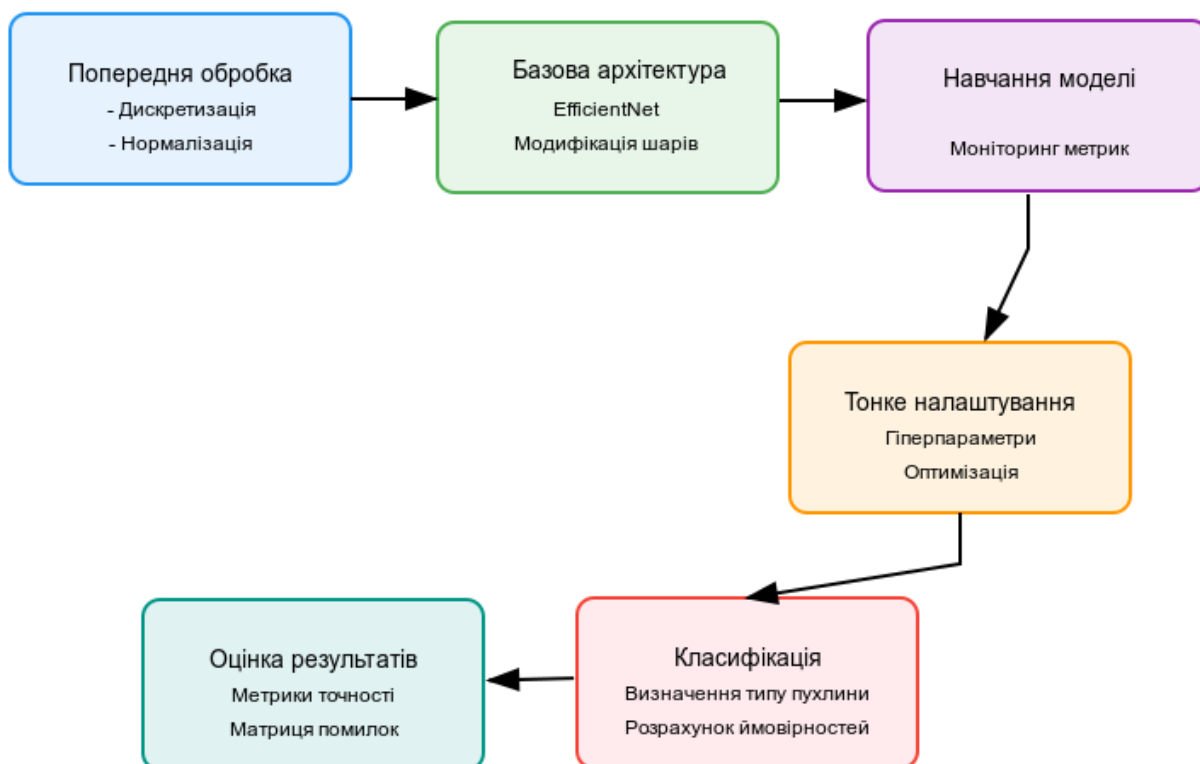


Рисунок 2.1 – Структура методу виявлення пухлин мозку на зображеннях МРТ

Процес починається з підготовки вхідних МРТ-зображень. На цьому кроці відбувається завантаження зображень різних форматів, включаючи DICOM, JPEG та PNG. Проводиться ретельна перевірка якості та цілісності кожного зображення, при цьому пошкоджені або неякісні зразки видаляються з набору даних. Всі зображення приводяться до єдиного стандартизованого формату для подальшої обробки.

Наступним важливим етапом є дискретизація зображень. В рамках цього процесу всі зображення масштабуються до єдиного розміру 400×400 пікселів зі збереженням правильного співвідношення сторін для уникнення спотворень. Зображення конвертуються в 3-канальний RGB формат, після чого проводиться нормалізація значень пікселів до діапазону від 0 до 1.

Для покращення якості зображень застосовується процедура видалення шуму. Використовується фільтр Гаусса з ядром розміром 3×3 , причому стандартне відхилення визначається автоматично для кожного зображення. Особлива увага приділяється збереженню важливих діагностичних деталей зображення під час фільтрації.

Важливим етапом є покращення контрасту зображень. Це досягається через нормалізацію гистограми та застосування адаптивного вирівнювання контрасту. Такі операції дозволяють підвищити видимість деталей пухлини та покращити загальну якість зображення для подальшого аналізу.

Сегментація області інтересу передбачає видалення фону та різноманітних артефактів. На цьому етапі виділяється область мозку та видаляється черепна коробка, залишаючи для аналізу тільки тканини мозку. Це дозволяє зосередити увагу моделі на релевантних областях зображення.

Для розширення навчального набору даних застосовується аугментація. Вона включає поворот зображень на випадковий кут до 20 градусів, горизонтальне та вертикальне віддзеркалення, масштабування в межах $\pm 10\%$, зсув зображення та зміну яскравості. Ці операції дозволяють створити більш різноманітний набір даних для навчання.

Після обробки відбувається розділення даних на три набори: навчальний (75%), валідаційний (15%) та тестовий (10%). При цьому забезпечується баланс класів у кожному наборі для уникнення зміщення при навчанні моделі.

Завершальним кроком є валідація якості обробки, що включає візуальну перевірку результатів, оцінку якості сегментації та перевірку збереження діагностично важливих деталей. При необхідності параметри обробки коригуються для досягнення оптимальних результатів.

Оброблені дані зберігаються у структурованому сховищі разом з метаданими обробки. Створюється ефективний вхідний пайплайн з генератором даних та оптимізованою пакетною обробкою для забезпечення ефективного навчання моделі. Весь процес попередньої обробки ретельно документується для забезпечення відтворюваності результатів.

Етап базової архітектури є ключовим компонентом методу, оскільки визначає основу для подальшої класифікації пухлин мозку. В якості базової архітектури використовується попередньо навчена модель EfficientNet, яка довела свою ефективність у задачах комп'ютерного зору.

Базова архітектура починається з завантаження попередньо навчених ваг моделі EfficientNet з набору даних ImageNet. Ця модель була обрана через її оптимальний баланс між обчислювальною складністю та якістю результатів. EfficientNet використовує принцип складеного масштабування, що дозволяє ефективно балансувати глибину, ширину та роздільну здатність мережі.

Після завантаження відбувається модифікація архітектури для адаптації до конкретної задачі класифікації пухлин мозку. Спочатку видаляються останні три класифікаційні шари оригінальної моделі, оскільки вони були налаштовані на класифікацію об'єктів ImageNet. Замість них додається нова послідовність шарів, оптимізована для класифікації пухлин.

Першим новим шаром є GlobalAveragePooling2D, який виконує глобальне усереднення просторових даних. Цей шар значно зменшує кількість параметрів моделі та допомагає боротися з перенавчанням. Він також забезпечує інваріантність до просторових трансформацій вхідних даних.

Наступним додається dropout шар з коефіцієнтом відсіву 0.05. Цей шар служить для регуляризації моделі, випадково відключаючи певний відсоток нейронів під час навчання. Такий підхід запобігає надмірній кореляції між нейронами та покращує узагальнюючу здатність мережі.

Завершальним елементом архітектури є щільний шар з кількістю нейронів, що відповідає кількості класів пухлин (у даному випадку – три нейрони для класифікації гліоми, менінгіоми та пухлини гіпофіза). Цей шар використовує функцію активації softmax, яка перетворює вихідні значення у ймовірності належності до кожного класу.

В архітектурі також застосовується L2-регуляризація з коефіцієнтом 0.1 для запобігання перенавчанню. Це допомагає контролювати величину ваг мережі та покращує її узагальнюючі властивості. Всі шари моделі налаштовані на обробку вхідних даних у форматі тензорів розміром $400 \times 400 \times 3$.

Для забезпечення ефективного навчання в архітектурі використовується механізм пакетної нормалізації. Це дозволяє стабілізувати процес навчання та прискорити збіжність моделі. Крім того, застосовуються залишкові з'єднання, які покращують потік градієнтів через мережу.

Архітектура також включає механізми уваги, які допомагають моделі фокусуватися на найбільш важливих частинах зображення. Це особливо важливо для медичних зображень, де ключові діагностичні ознаки можуть займати невелику частину загального зображення.

Важливою особливістю архітектури є її здатність до масштабування. При необхідності можна легко змінювати кількість шарів та їх параметри, зберігаючи при цьому загальну структуру мережі. Це забезпечує гнучкість у налаштуванні моделі під конкретні вимоги та обмеження.

Розроблена базова архітектура забезпечує надійну основу для подальшого навчання та точної класифікації пухлин мозку на МРТ-зображеннях. Вона поєднує в собі переваги сучасних підходів до глибокого навчання та специфічні особливості, необхідні для роботи з медичними зображеннями.

Етап тонкого налаштування (fine-tuning) є критично важливим для адаптації попередньо навченої моделі до конкретної задачі класифікації пухлин мозку. В рамках цього етапу відбувається точне налаштування параметрів моделі для досягнення максимальної ефективності.

Процес починається з заморожування ваг базових згорткових шарів EfficientNet. Це означає, що під час навчання оновлюються лише ваги нових доданих шарів, тоді як ваги базової моделі залишаються незмінними. Такий підхід дозволяє зберегти корисні ознаки, вивчені на наборі даних ImageNet, і при цьому адаптувати модель до специфіки МРТ-зображень.

Важливим аспектом тонкого налаштування є вибір оптимізатора. У даному методі використовується RectifiedAdam - вдосконалена версія оптимізатора Adam, яка забезпечує кращу збіжність. Параметри оптимізатора встановлюються наступним чином: початкова швидкість навчання становить 0.0001, коефіцієнти $\beta_1 = 0.9$ та $\beta_2 = 0.999$, $\epsilon = 1e-08$.

В якості функції втрат обрано categorical crossentropy, яка добре підходить для задач багатокласової класифікації. Ця функція вимірює розбіжність між прогнозованими ймовірностями та істинними мітками класів, що дозволяє ефективно навчати модель розрізняти різні типи пухлин. Для запобігання перенавчанню використовується техніка раннього зупинення (early stopping) з параметром терпіння 5 епох. Це означає, що навчання припиняється, якщо протягом 5 послідовних епох не спостерігається покращення показників на валідаційному наборі.

Також застосовується динамічне зменшення швидкості навчання за допомогою callback-функції ReduceLROnPlateau. При відсутності покращення метрик протягом певного періоду швидкість навчання зменшується на фактор 0.3, що допомагає моделі знайти кращий локальний мінімум.

Розмір пакету встановлюється на рівні 32 зображень, що забезпечує оптимальний баланс між швидкістю навчання та використанням пам'яті. Кількість кроків на епоху розраховується автоматично залежно від розміру навчального набору даних.

Процес тонкого налаштування також включає регуляризацію моделі. Окрім dropout, застосовується L2-регуляризація з коефіцієнтом 0.1 для контролю величини ваг мережі. Це допомагає запобігти перенавчанню та покращує узагальнюючі властивості моделі.

Під час навчання відстежуються різні метрики, включаючи точність, втрати, чутливість та специфічність. Це дозволяє контролювати процес навчання та вносити необхідні корективи в параметри моделі.

Таким чином, етап тонкого налаштування забезпечує ефективну адаптацію попередньо навченої моделі до специфічної задачі класифікації пухлин мозку. Ретельний підбір гіперпараметрів та використання сучасних технік оптимізації дозволяють досягти високої точності класифікації при збереженні хорошої узагальнюючої здатності моделі. Етап навчання моделі є ключовим у всьому процесі створення системи класифікації пухлин мозку. На цьому етапі відбувається безпосереднє навчання моделі на підготовлених даних з використанням налаштованих параметрів.

Процес навчання починається з ініціалізації моделі з попередньо визначеними параметрами та архітектурою. Навчальний набір даних, що становить 75% від загального обсягу, подається в модель послідовними пакетами по 32 зображення. Валідаційний набір, що складає 15% даних, використовується для оцінки ефективності навчання після кожної проведеної епохи.

Загальна тривалість навчання становить 50 епох, протягом яких модель багаторазово обробляє весь навчальний набір даних. Під час кожної епохи відбувається коригування ваг мережі на основі розрахованої функції втрат та її градієнтів. Оптимізатор RectifiedAdam автоматично адаптує швидкість навчання для кожного параметра мережі.

В процесі навчання постійно відстежуються ключові метрики продуктивності. Точність та функція втрат обчислюються як для навчального, так і для валідаційного наборів даних. Це дозволяє виявляти можливе перенавчання моделі та оцінювати якість генералізації.

Важливим аспектом процесу навчання є використання callback-функцій. ModelCheckpoint зберігає ваги моделі при досягненні найкращих показників на валідаційному наборі. EarlyStopping відстежує динаміку навчання і може зупинити процес, якщо не спостерігається покращення результатів протягом визначеного періоду.

Під час навчання також відбувається динамічна корекція швидкості навчання. Якщо протягом кількох епох не спостерігається покращення метрик, ReduceLROnPlateau зменшує швидкість навчання, що допомагає моделі подолати локальні мінімуми функції втрат. Процес навчання супроводжується візуалізацією прогресу. Графіки зміни точності та втрат будуються в реальному часі, що дозволяє відстежувати динаміку навчання та виявляти потенційні проблеми. Також відображається поточна швидкість навчання та інші важливі параметри.

Кожна епоха навчання включає перемішування навчальних даних для запобігання впливу порядку подачі зразків на результат навчання. Аугментація даних виконується в реальному часі, створюючи додаткову варіативність навчальних прикладів.

В кінці кожної епохи проводиться повна оцінка моделі на валідаційному наборі даних. Розраховуються метрики точності. Ці показники використовуються для прийняття рішення про продовження або припинення навчання. Після завершення навчання виконується фінальне тестування моделі на відкладеному тестовому наборі даних, який становить 10% від загального обсягу. Це дозволяє отримати об'єктивну оцінку якості навченої моделі на раніше не бачених даних.

Результатом етапу навчання є повністю навчена модель, здатна ефективно класифікувати пухлини мозку на МРТ-зображеннях. Модель зберігається разом з усіма необхідними параметрами та метаданими для подальшого використання в клінічній практиці.

Етап класифікації є головним всього методу, де навчена модель застосовується для безпосереднього визначення типу пухлин мозку на нових МРТ-зображеннях. Цей етап реалізує застосування розробленої практичної системи в реальних умовах застосування.

Процес класифікації починається з отримання нового МРТ-зображення для аналізу. Вхідне зображення проходить ту ж попередню обробку, що застосовувалася під час навчання: масштабування до розміру 400×400 пікселів, нормалізація значень пікселів, фільтрація шуму та покращення контрасту.

Після попередньої обробки зображення подається на вхід навченої моделі EfficientNet. Модель виконує послідовну обробку через всі шари нейронної мережі, починаючи зі згорткових шарів, які виділяють характерні ознаки зображення, і закінчуючи повнозв'язними шарами, які виконують фінальну класифікацію.

На виході моделі формується вектор ймовірностей належності зображення до кожного з трьох класів пухлин: гліоми, менингіоми та пухлини гіпофіза. Функція активації softmax забезпечує, що сума ймовірностей дорівнює одиниці, а кожна ймовірність знаходиться в діапазоні від 0 до 1.

Важливим аспектом класифікації є визначення порогового значення для прийняття рішення. Зазвичай клас з найвищою ймовірністю вважається результатом класифікації, однак система також може видавати попередження, якщо різниця між найвищими ймовірностями незначна, що вказує на невизначеність класифікації.

Система також генерує результат класифікації. Це дозволяє визначити на вхідному зображенні ті області, які модель вважає найбільш важливими для прийняття рішення. Таке представлення допомагає лікарям верифікувати результати класифікації.

Результати класифікації представляються у вигляді звіту, який включає: визначений тип пухлини, ймовірності належності до кожного класу, визначення областей інтересу та додаткові метрики впевненості моделі у своєму рішенні.

При виникненні випадків з низькою впевненістю класифікації система може позначати їх як такі, що потребують додаткової уваги лікаря. Це забезпечує додатковий рівень безпеки при використанні системи в клінічній практиці.

Система також зберігає результати класифікації разом з вхідними даними та проміжними результатами обробки. Це дозволяє проводити подальший аналіз ефективності роботи системи та її вдосконалення на основі накопиченого досвіду.

Таким чином, етап класифікації забезпечує не тільки визначення типу пухлини, але й надає лікарям додаткову інформацію для прийняття обґрунтованих клінічних рішень. Система працює як інструмент підтримки прийняття рішень, доповнюючи, але не замінюючи експертну оцінку лікаря.

Етап оцінки результатів є заключним і критично важливим компонентом методу, який забезпечує комплексну оцінку ефективності розробленої системи класифікації пухлин мозку на МРТ-зображеннях.

Оцінка починається з розрахунку основних метрик продуктивності на тестовому наборі даних. Загальна точність (precision) моделі розраховується як відношення правильно класифікованих випадків до загальної кількості випадків.

Чутливість (recall) моделі оцінюється окремо для кожного типу пухлин і показує здатність системи правильно ідентифікувати позитивні випадки.

Матриця помилок будується для детального аналізу помилок класифікації. Вона показує розподіл правильних та неправильних класифікацій для кожного типу пухлин, дозволяючи виявити систематичні помилки в роботі моделі. Проводиться аналіз складних випадків, де система показала низьку впевненість або зробила помилкові класифікації. Це дозволяє виявити потенційні обмеження системи та напрямки для подальшого вдосконалення.

Виконується оцінка обчислювальної ефективності системи, включаючи час обробки одного зображення та вимоги до обчислювальних ресурсів. Це важливо для практичного впровадження системи в клінічну практику. Результати оцінки порівнюються з існуючими методами та системами класифікації пухлин мозку. Це дозволяє визначити переваги та недоліки розробленого методу в порівнянні з іншими підходами.

Формується детальний звіт з результатами оцінки, який включає всі розраховані метрики, графіки, аналіз помилок та рекомендації щодо використання системи в клінічній практиці. Цей звіт служить основою для прийняття рішення про можливість впровадження системи в реальну медичну практику.

2.6 Структура методу виявлення пухлин із застосуванням трансферного навчання

Вдосконалений метод виявлення та класифікації пухлин мозку на МРТ-зображеннях містить ряд суттєвих відмінностей та покращень у порівнянні з традиційними підходами.

В області архітектури та навчання головною відмінністю є інтеграція механізму трансферного навчання з використанням попередньо навченої моделі EfficientNet. Це доповнюється етапом тонкого налаштування з вибірковою заморожуванням шарів, що дозволяє зберегти корисні ознаки базової моделі при адаптації до нової задачі. Впроваджено адаптивний механізм навчання з динамічною корекцією швидкості, що забезпечує більш ефективне навчання моделі.

Суттєві удосконалення внесено в область попередньої обробки даних. Розширено методи аугментації даних, що покращує здатність моделі до генералізації. Додано адаптивну нормалізацію контрасту, яка враховує особливості МРТ-зображень. Процес видалення шуму також було вдосконалено з урахуванням специфіки медичних зображень.

В області класифікації впроваджено новий механізм оцінки невизначеності, який дозволяє виявляти випадки з низькою впевненістю класифікації. Додано визначення областей інтересу, що підвищує інтерпретованість результатів. Реалізовано систему при низькій впевненості класифікації, що підвищує безпеку використання системи.

Значні покращення внесено в область оцінки результатів. Розширено набір метрик оцінки ефективності, що дозволяє більш комплексно оцінювати якість роботи системи. Додано аналіз складних випадків, який допомагає виявляти потенційні обмеження методу. Впроваджено порівняльний аналіз з існуючими методами, що дозволяє об'єктивно оцінити переваги розробленого підходу.

Основною перевагою вдосконаленого методу є підвищена точність класифікації. Це доповнюється покращеною здатністю до генералізації та зменшеною потребою в розмірі навчальної вибірки. Більша інтерпретованість

результатів та краща адаптація до реальних клінічних умов роблять метод більш придатним для практичного застосування.

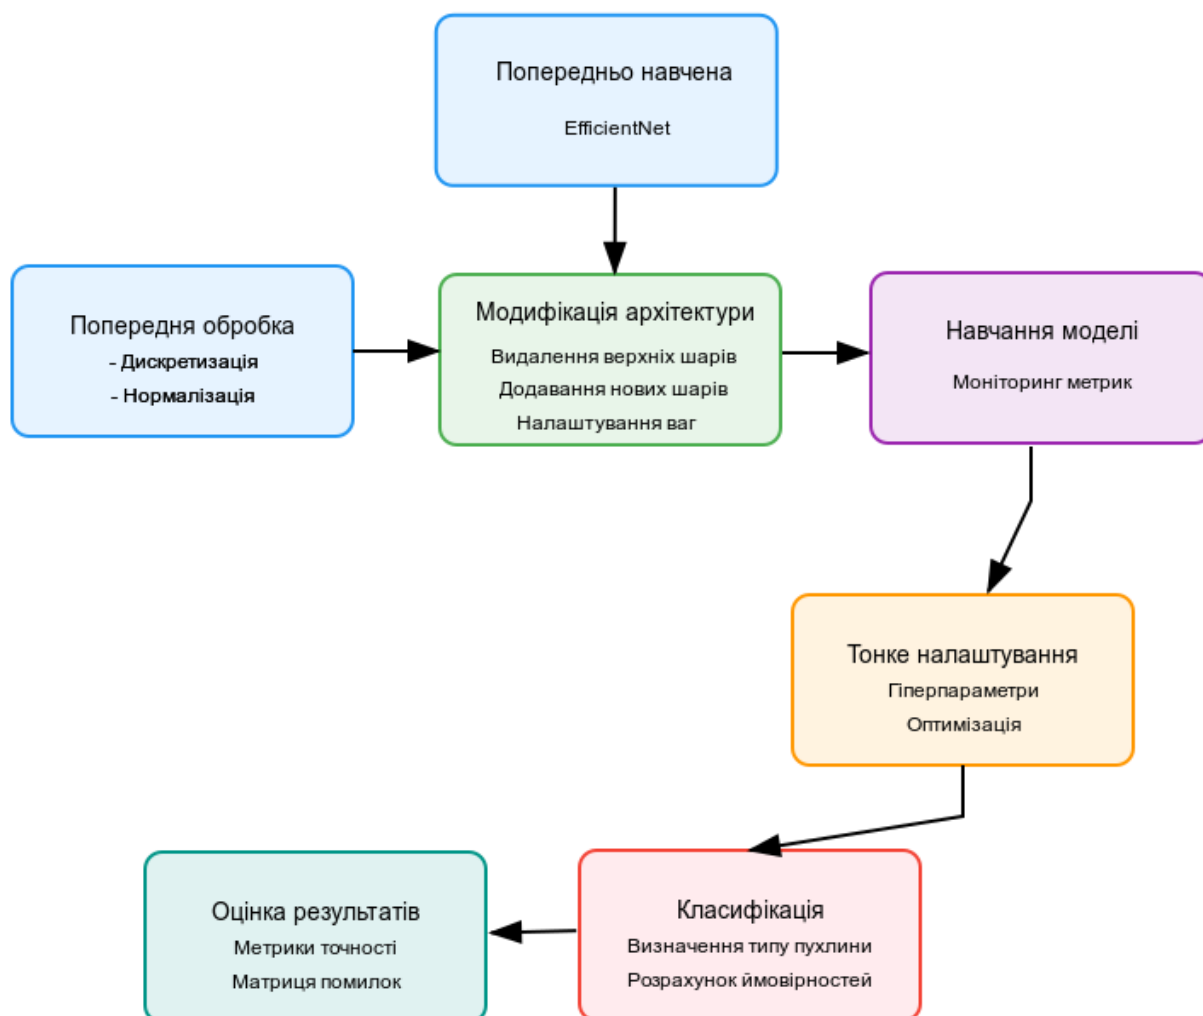


Рисунок 2.2 – Структура методу виявлення пухлин із застосуванням трансферного навчання

Завдяки цим удосконаленням метод забезпечує більш надійну та точну класифікацію пухлин мозку. Інтеграція трансферного навчання дозволяє ефективно використовувати знання, отримані на великих наборах даних, для вирішення специфічної медичної задачі. Комплексний підхід до оцінки результатів та наявність механізмів забезпечення безпеки роблять систему придатною для впровадження в реальну клінічну практику.

Всі ці удосконалення разом створюють більш надійну та ефективну систему для діагностики пухлин мозку, яка може служити важливим інструментом підтримки прийняття рішень у медичній практиці. Метод демонструє високу точність при збереженні практичної застосовності та надійності, що є критично важливим для медичних застосувань.

2.7 Формування базової моделі у класифікації зображень.

На етапі підготовки моделі головною задачею є ефективне використання попередньо навченої архітектури для класифікації пухлин мозку. Спершу вибирається модель EfficientNet, яка відзначається високою ефективністю завдяки оптимізованій структурі і здатності працювати з меншими обчислювальними ресурсами. Ця модель була навчена на препроцесінгу на великому наборі даних ImageNet, що дозволяє їй зберігати багатий набір базових ознак, корисних для аналізу зображень.

Після вибору моделі здійснюється адаптація до нової задачі шляхом трансферного навчання. Основна ідея цього процесу полягає в тому, щоб перенести знання, які модель вже отримала під час початкового навчання, на специфічну задачу класифікації медичних зображень. Для цього більшість внутрішніх шарів EfficientNet заморожуються, тобто їх ваги залишаються незмінними. Це дозволяє зберегти вже вивчені базові ознаки, наприклад, розпізнавання текстур, контурів або форм, що характерні для зображень.

На наступному етапі виконується тонке налаштування. Для цього розморожуються лише верхні шари моделі, які відповідають за спеціалізовані ознаки. Ці шари перенавчаються на даних МРТ, щоб модель могла краще адаптуватися до виявлення специфічних особливостей пухлин мозку, таких як розмір, форма або аномальна структура тканин.

Ключовим удосконаленням є використання адаптивного механізму навчання, який динамічно змінює швидкість навчання в залежності від стадії тренування. На початкових етапах швидкість є вищою, що прискорює процес знаходження

оптимальних ваг, але поступово зменшується, щоб уникнути осциляцій і забезпечити стабільну конвергенцію.

Результатом цього етапу є глибока нейронна мережа, яка оптимізована для роботи з МРТ-зображеннями і здатна ефективно виконувати класифікацію пухлин мозку з урахуванням їх специфічних характеристик.

Застосування трансферного навчання відбувається наступним чином.

На першому кроці отримуємо попередньо навчену модель.

Модель:

$$f(x; \theta_{\text{pretrain}}), \quad (2.1)$$

де x – вхідне зображення;

θ_{pretrain} – параметри, навчені на великому наборі даних, таких як ImageNet.

Наступний кроком є заморожування шарів.

Заморожування параметрів θ_{frozen} для шарів базової частини моделі:

$$\theta_{\text{frozen}} = \{\theta_i \mid i \in L_{\text{frozen}}\}, \quad (2.2)$$

де L_{frozen} – множина індексів шарів, що не оновлюються під час навчання.

$$\frac{\partial L}{\partial \theta_i} = 0, \quad \forall i \in L_{\text{frozen}}, \quad (2.3)$$

де L – функція втрат.

Наступний крок це тонке налаштування.

Параметри верхніх шарів $\theta_{\text{fine-tune}}$ налаштовуються для нової задачі на основі набору даних

$$D_{\text{MRI}} = \{(x_j, y_j)\} \quad (2.4)$$

де y_j – мітки класів.

$$\begin{aligned}\theta_{\text{fine-tune}} &= \{\theta_i \mid i \in L_{\text{fine-tune}}\}, \\ L_{\text{fine-tune}} \cap L_{\text{frozen}} &= \emptyset.\end{aligned}\tag{2.5}$$

Параметри оновлюються з урахуванням похідної функції втрат:

$$\theta_{\text{fine-tune}}^{(t+1)} = \theta_{\text{fine-tune}}^{(t)} - \eta_t \frac{\partial L}{\partial \theta_{\text{fine-tune}}^{(t)}},\tag{2.6}$$

де η_t – адаптивна швидкість навчання на ітерації t .

Також застосована адаптивна швидкість навчання.

Швидкість навчання змінюється за формулою:

$$\eta_t = \eta_0 \cdot \frac{1}{1 + \lambda t},\tag{2.7}$$

де η_0 – початкова швидкість навчання;

λ – параметр, що контролює зменшення швидкості;

t – номер ітерації.

Далі необхідно визначити функцію втрат.

Функція втрат визначається як крос-ентропія:

$$L = -\frac{1}{N} \sum_{j=1}^N \sum_{k=1}^K y_{j,k} \log(\hat{y}_{j,k}),\tag{2.8}$$

де N – кількість прикладів у міні пакеті;

K – кількість класів;

$y_{\{j,k\}}$ – реальний клас;

$\hat{y}_{j,k}$ – ймовірність, передбачена моделлю.

Наступним кроком є валідація і тестування.

Для цього здійснимо розділення даних на підмножини D_{train} , D_{val} , D_{test} для перевірки узагальнюючої здатності моделі.

Цей підхід описує ключові аспекти адаптації моделі в рамках етапів методу.

Висновки до розділу 2

У розділі було запропоновано метод виявлення пухлин мозку на зображеннях МРТ із застосуванням нейромережових засобів. Основним етапом методу є виокремлення структур на зображеннях за допомогою згорткових нейронних мереж та сегментаційних операцій. Далі здійснюється виділення об'єктів на зображеннях з метою визначення місця розташування потенційних пухлин. Наступним кроком є побудова спеціалізованої архітектури згорткової нейронної мережі для класифікації зображень на наявність чи відсутність пухлин. Для підвищення ефективності навчання нейронної мережі застосовується диференційоване навчання. Крім того, використовується трансферне навчання та попередньо навчена на великому наборі даних базова модель для прискорення процесу навчання та підвищення точності.

Описано структуру розробленого методу, включаючи деталі попередньої обробки зображень, архітектури мережі та способу вибраного навчання. Ключовими перевагами запропонованого підходу є висока точність виявлення пухлин, можливість працювати з малими наборами даних завдяки трансферному навчанню, а також швидкість та ефективність за рахунок використання попередньо навченої базової моделі. Метод може бути використаний у медичній діагностиці для раннього та точного виявлення пухлин мозку, що є критично важливим для успішного лікування.

РОЗДІЛ 3 Архітектура методу виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами

3.1 Загальна архітектура методу

Архітектура запропонованого методу виявлення пухлин мозку на МРТ-зображеннях складається з п'яти основних модулів, які забезпечують повний цикл обробки від вхідного зображення до кінцевого результату класифікації.

Модуль попередньої обробки відповідає за підготовку вхідних даних. У рамках цього модуля здійснюється стандартизація розмірів МРТ-зображень до єдиного формату 224×224 пікселі, що забезпечує однорідність вхідних даних для робочої нейронної мережі. Далі потрібно виконати нормалізацію інтенсивності пікселів до діапазону від 0 до 1, що покращує стабільність навчання мережі. Застосовується фільтрація шуму за допомогою фільтра Гаусса та адаптивне вирівнювання гістограми для покращення контрастності зображень.

Ядром системи є модифікована архітектура EfficientNet, попередньо навчена мережа на тренувальному наборі даних ImageNet. Архітектура була адаптована для задачі класифікації пухлин мозку шляхом модифікації верхніх шарів мережі. Додано шар глобального усереднення, dropout для регуляризації та новий щільний шар з трьома виходами, що відповідають різним типам пухлин.

Процес навчання реалізовано з використанням трансферного навчання, де базові шари мережі залишаються замороженими, а навчаються лише нові шари. Застосовується оптимізатор RectifiedAdam з адаптивною швидкістю навчання та методи аугментації даних для підвищення стійкості моделі.

Модуль виведення забезпечує обробку вхідних зображень в режимі реального часу, включаючи попередню обробку, проходження через нейронну мережу та формування результатів класифікації. Додатково генеруються карти активації, що допомагають візуалізувати області інтересу на зображеннях.

Модуль аналізу результатів відповідає за розрахунок метрик якості класифікації, формування матриці помилок та оцінку невизначеності класифікації. Реалізовано результатів у зручному для користувача форматі.

Для функціонування системи необхідне програмне середовище Python версії 3.8 або вище, фреймворк TensorFlow 2.6+, а також бібліотеки OpenCV, NumPy та Pandas. Рекомендується наявність GPU з підтримкою CUDA для прискорення обчислень. Мінімальний обсяг оперативної пам'яті становить 8 ГБ.

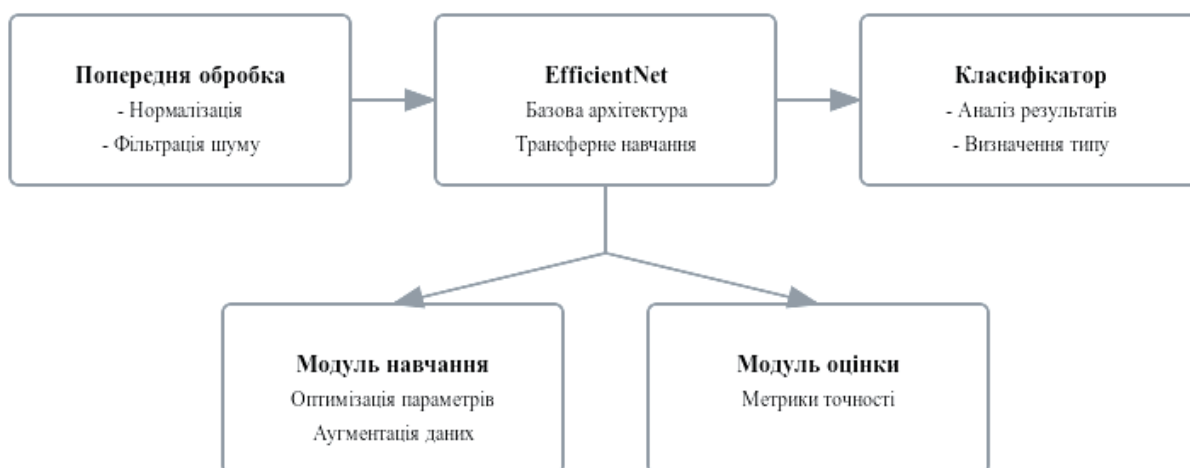


Рисунок 3.1 – Архітектура методу виявлення пухлин мозку

Схема відображає основні компоненти та їх взаємозв'язки в архітектурі методу виявлення пухлин мозку на МРТ-зображеннях. На схемі представлено:

1. Модуль попередньої обробки, що відповідає за підготовку вхідних даних.
2. EfficientNet як основну архітектуру нейронної мережі.
3. Класифікатор для визначення типу пухлини.
4. Модуль навчання, що включає оптимізацію та аугментацію даних.
5. Модуль оцінки для аналізу результатів.

Архітектура розроблена з урахуванням принципів модульності та розширюваності, що дозволяє легко оновлювати та вдосконалювати окремі компоненти системи без порушення її цілісності. Всі модулі правильно взаємодіють через реалізовані програмні інтерфейси, забезпечуючи надійність та стабільність роботи системи в цілому.

3.2 Попередня обробка та підготовка МРТ-зображень

Спочатку застосуємо методи нормалізації даних. Нормалізація інтенсивності пікселів МРТ-зображень здійснюється через розподіл значень у діапазоні $[0,1]$. Цей процес виконується для кожного зображення окремо з використанням формули:

$$I_{norm} = \frac{I - I_{min}}{I_{max} - I_{min}} \quad (3.1)$$

де I – початкове значення пікселя;

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

Додатково виконується z-нормалізація для приведення розподілу значень до нормального з нульовим середнім та одиничною дисперсією.

Для зменшення рівня шуму на МРТ-зображеннях використовується багатоетапний підхід. Спочатку застосовується гауссовий фільтр з ядром розміром 3×3 та стандартним відхиленням $\sigma = 0.5$. Цей етап дозволяє усунути високочастотний шум при збереженні важливих структурних деталей. Наступним кроком є анізотропна дифузійна фільтрація, що забезпечує згладжування в однорідних областях при збереженні країв об'єктів.

Покращення контрастності реалізовано через адаптивне вирівнювання гістограми. Алгоритм працює з локальними областями розміром 8×8 пікселів, застосовуючи обмеження контрасту на рівні 0.02 для запобігання надмірному підсиленню шуму. Додатково використовується гамма-корекція з адаптивним коефіцієнтом, що визначається на основі аналізу гістограми конкретного зображення.

Стандартизація розмірів здійснюється через бікубічну інтерполяцію до цільового розміру 224×224 пікселі. Цей розмір обрано як оптимальний для роботи з архітектурою EfficientNet та забезпечення балансу між збереженням деталей та

обчислювальною ефективністю. При масштабуванні зберігається співвідношення сторін оригінального зображення через додавання відступів нульовими значеннями.

3.3 Алгоритм попередньої обробки зображень

Послідовність обробки зображень включає наступні етапи:

1. Завантаження зображення в пам'ять та конвертація в формат з плаваючою комою.
2. Масштабування до стандартного розміру.
3. Фільтрація шуму.
4. Нормалізація інтенсивності.
5. Покращення контрастності.
6. Валідація результатів обробки.

Кожен етап має вбудовані механізми перевірки якості та можливість адаптивного налаштування параметрів залежно від характеристик вхідного зображення. Результати попередньої обробки зберігаються в проміжному форматі, оптимізованому для подальшого аналізу використаною нейронною мережею.

Алгоритм для необхідної обробки зображень складається з декількох послідовних етапів обробки та точок контролю якості.

Спочатку виконується завантаження вихідного МРТ-зображення в пам'ять системи. На цьому етапі проводиться первинна перевірка цілісності та якості зображення. Якщо зображення не відповідає базовим вимогам якості, система генерує повідомлення про помилку та припиняє обробку.

При успішній перевірці зображення масштабується до стандартного розміру 224×224 пікселі з використанням бікубічної інтерполяції. Цей розмір обрано як оптимальний для подальшої обробки нейронною мережею.

Наступним кроком є конвертація зображення у відповідний формат та застосування фільтрації шуму. Використовується комбінація гауссового фільтра та анізотропної дифузійної фільтрації для збереження важливих діагностичних ознак при видаленні шуму.

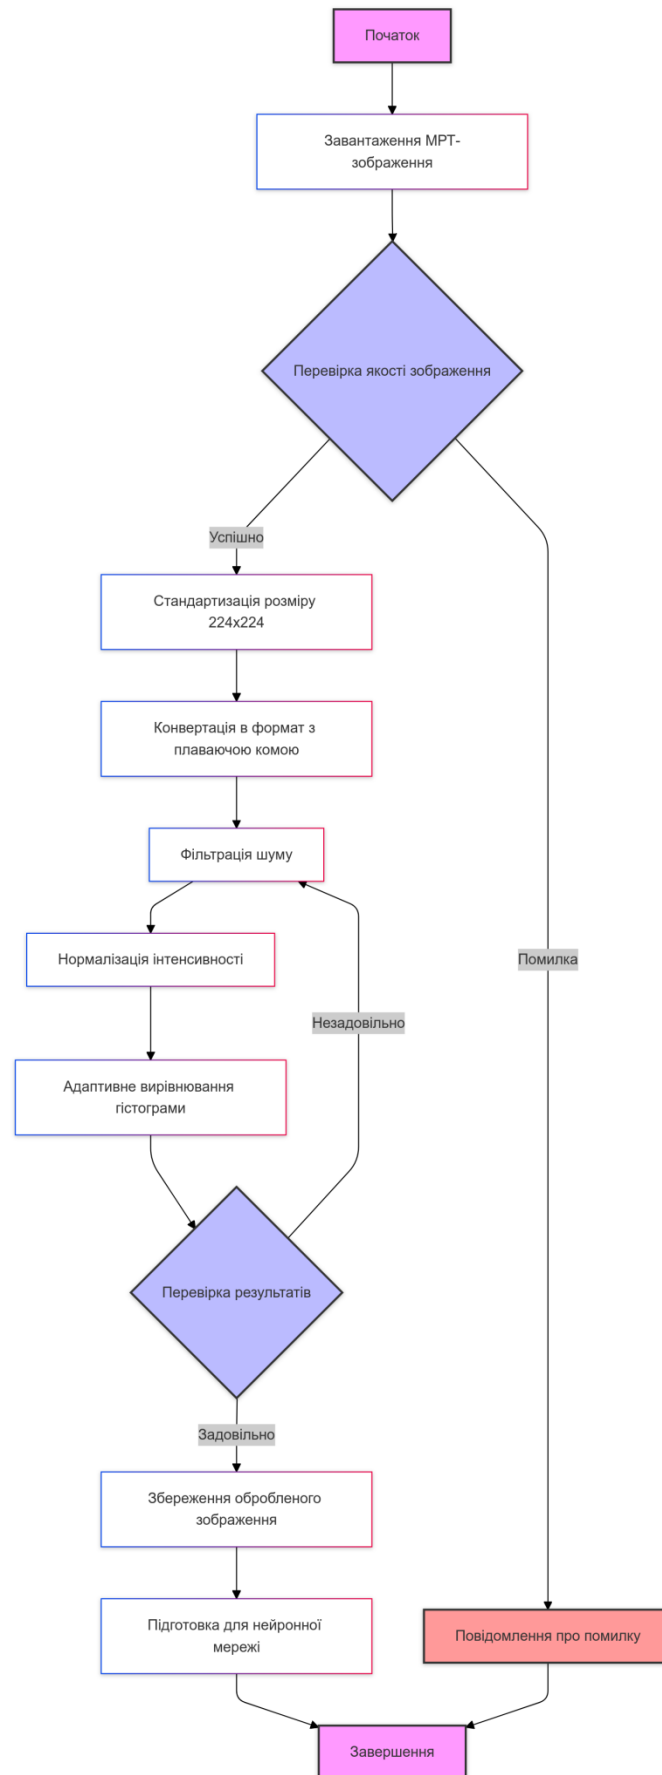


Рисунок 3.2 – Алгоритм попередньої обробки зображень

Далі виконується нормалізація інтенсивності пікселів до діапазону $[0,1]$ та адаптивне вирівнювання гистограми для покращення контрастності зображення. Результати обробки проходять перевірку якості, і при незадовільних результатах процес може бути повторений з модифікованими параметрами.

Фінальними етапами є збереження обробленого зображення та його підготовка для подачі на вхід розробленої мережі. В цьому етапі також формується службова інформація про параметри обробки для забезпечення відтворюваності результатів.

Важливою особливістю алгоритму є наявність зворотного зв'язку та можливість адаптивного налаштування параметрів обробки залежно від характеристик конкретного зображення. Це забезпечує стабільність та надійність процесу попередньої обробки.

Всі параметри попередньої обробки можуть бути адаптивно налаштовані для конкретного набору даних або вимог конкретної задачі. Система забезпечує відтворюваність результатів та можливість простежити всі етапи обробки для кожного зображення.

3.4 Модифікована архітектура нейронної мережі

Базова архітектура EfficientNet була обрана через її оптимальне співвідношення між обчислювальною ефективністю та якістю результатів. EfficientNet використовує принцип складеного масштабування, який дозволяє збалансовано змінювати глибину мережі, ширину та роздільну здатність вхідних даних. Базова архітектура складається з послідовності MBConv-блоків, які використовують глибинну згортку та точкову згортку для ефективної обробки ознак.

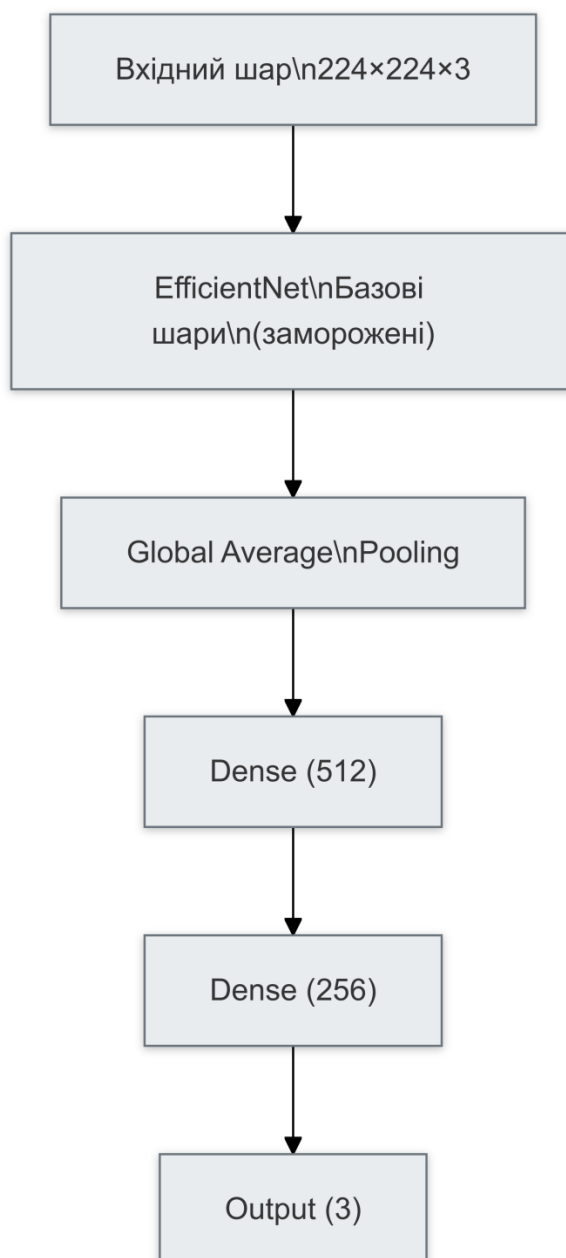


Рисунок 3.3 – Модифікована архітектура нейронної мережі

Щодо основних параметрів базової архітектури, вона приймає вхідні дані розміром 224×224×3 пікселів. Архітектура містить 237 шарів із загальною кількістю параметрів 5.3 мільйони. На наборі даних ImageNet мережа демонструє базову точність 84.4%.

Внесені модифікації та їх обґрунтування. Для адаптації до задачі виявлення пухлин мозку було внесено ряд суттєвих модифікацій. Насамперед, було вилучено останні три класифікаційні шари оригінальної мережі, оскільки вони були налаштовані на класифікацію об'єктів ImageNet. Натомість було додано нову

послідовність шарів, що включає шар глобального усереднення для зменшення розмірності даних та dropout шар з коефіцієнтом 0.5 для запобігання перенавчанню. Далі архітектуру доповнено двома повнозв'язними шарами з 512 та 256 нейронами відповідно, а також фінальним шаром з 3 виходами для класифікації типів пухлин.

Модифікована архітектура починається з вхідного шару розмірністю $224 \times 224 \times 3$, після якого йдуть заморожені базові шари EfficientNet. Наступним є шар глобального усереднення, за яким слідує dropout з коефіцієнтом 0.5. Далі йде повнозв'язний шар з 512 нейронами, доповнений batch normalization та ReLU активацією. Після нього розміщено dropout з коефіцієнтом 0.3 та другий повнозв'язний шар з 256 нейронами, також з batch normalization та ReLU. Завершує архітектуру повнозв'язний шар з 3 нейронами та функцією активації softmax.

У проміжних шарах мережі використовується функція активації ReLU для забезпечення нелінійності та запобігання проблемі затухаючих градієнтів. У вихідному шарі застосовується функція softmax для отримання розподілу ймовірностей між класами. В якості функції втрат використовується категоріальна крос-ентропія з L2-регуляризацією, де коефіцієнт регуляризації становить 0.01. Для покращення роботи з незбалансованими класами додатково застосовується фокальна втрата, яка модифікує стандартну крос-ентропію за формулою

$$FL(p_t) = -\alpha(1-p_t)^\gamma \log(p_t), \quad (3.2)$$

де α – виступає балансуєчим коефіцієнтом;

γ – є фокусуєчим параметром;

p_t – представляє ймовірність правильного класу.

3.5 Реалізація трансферного навчання

Для ефективного використання трансферного навчання було застосовано стратегію поетапної адаптації попередньо навченої моделі EfficientNet. На першому етапі використовувалися ваги, отримані при навчанні на наборі даних ImageNet, що

забезпечило початкове розуміння базових візуальних ознак зображень. Важливим аспектом стратегії стало збереження нижніх шарів мережі, які відповідають за вилучення простих візуальних ознак, таких як краї, текстури та базові геометричні патерни, оскільки ці ознаки є універсальними для різних типів зображень.

Тонке налаштування моделі здійснювалося через поетапний процес розморожування шарів. Спочатку навчалися лише нові класифікаційні шари з замороженим базовим екстрактором ознак. Після досягнення початкової збіжності на нових шарах, поступово розморожувалися верхні шари базової мережі. При цьому використовувалася диференційована швидкість навчання: нижчі показники для раніше навчених шарів та вищі для нових. Такий підхід дозволив зберегти корисні ознаки, отримані при попередньому навчанні, одночасно адаптуючи мережу до специфіки медичних зображень.

Для контролю перенавчання під час трансферного навчання впроваджено комплексний підхід регуляризації. Використовується динамічна зміна коефіцієнта L2-регуляризації залежно від глибини шару: сильніша регуляризація застосовується до нових шарів та слабша до попередньо навчених. Dropout шари з адаптивними коефіцієнтами відсіву застосовуються між повнозв'язними шарами, причому їх значення коригуються на основі моніторингу валідаційних метрик. Batch normalization використовується з фіксованими статистиками для попередньо навчених шарів та оновлюваними для нових, що забезпечує стабільність навчання.

Процес навчання різних шарів мережі організовано з урахуванням їх ролі та початкового стану. Нижні шари, що відповідають за базове вилучення ознак, навчаються з найнижчою швидкістю навчання, оскільки їх ваги вже добре налаштовані на розпізнавання базових візуальних патернів. Середні шари, які відповідають за більш специфічні ознаки, навчаються з помірною швидкістю, що дозволяє їм адаптуватися до особливостей медичних зображень. Верхні шари, включаючи нові класифікаційні шари, навчаються з найвищою швидкістю, оскільки вони потребують найбільшої адаптації до нового завдання. Такий диференційований підхід забезпечує оптимальний баланс між збереженням корисних попередньо навчених ознак та адаптацією до нового домену даних.

У процесі трансферного навчання здійснюється постійний моніторинг ключових метрик продуктивності мережі. На кожній епісі відстежуються значення функції втрат та точності як на тренувальному, так і на валідаційному наборах даних. Окрім базових метрик, впроваджено відстеження градієнтних норм для різних груп шарів, що дозволяє виявляти потенційні проблеми в процесі навчання, такі як затухання чи вибух градієнтів. Система моніторингу також включає візуалізацію активацій проміжних шарів, що допомагає зрозуміти, як мережа адаптується до нового домену даних.

Система трансферного навчання включає механізми адаптивного налаштування гіперпараметрів на основі спостережуваної динаміки навчання. Швидкість навчання коригується окремо для кожної групи шарів на основі їх градієнтних статистик. Коефіцієнти регуляризації автоматично налаштовуються залежно від спостережуваного рівня перенавчання на валідаційному наборі. Розмір міні-батчів динамічно змінюється для оптимізації використання обчислювальних ресурсів та забезпечення стабільності навчання.

В процесі трансферного навчання враховуються специфічні особливості медичних зображень. Впроваджено спеціалізовані шари попередньої обробки, які враховують характеристики МРТ-зображень, такі як нормалізація інтенсивності та корекція неоднорідності поля. Архітектура мережі модифікована для кращої роботи з напівпрозорими структурами та градієнтними переходами, характерними для медичних зображень. Додатково враховуються особливості розподілу інтенсивностей в різних режимах МРТ-сканування.

Для оцінки ефективності трансферного навчання використовується багаторівнева система валідації. Окрім стандартного розділення даних на тренувальну та валідаційну вибірки, застосовується крос-валідація для оцінки стабільності навчання. Тестування моделі проводиться на незалежному наборі даних, який не використовувався під час навчання та валідації. Особлива увага приділяється оцінці генералізації моделі на зображеннях з різних медичних установ та отриманих на різному обладнанні.

При реалізації трансферного навчання враховано необхідність ефективного використання обчислювальних ресурсів. Впроваджено механізми градієнтної акумуляції для роботи з обмеженою пам'яттю, оптимізовано завантаження та попередню обробку даних для зменшення затримок при навчанні. Використовується змішана точність обчислень для прискорення навчання при збереженні точності результатів. Реалізовано механізми чекпойнтів для можливості відновлення навчання після переривання.

3.6 Метрики визначення якості розробленого методу

Розглянемо основні метрики оцінки ефективності, які використовуються для оцінки класифікації та сегментації пухлин мозку на МРТ-зображеннях.

Коефіцієнт Dice (Dice Similarity Coefficient, DSC):

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|} \quad (3.3)$$

де X та Y – множини пікселів сегментованої області та еталонної маски відповідно. DSC приймає значення від 0 до 1, де 1 означає повне співпадіння. Ця метрика є симетричною і добре підходить для оцінки просторового перекриття сегментацій.

Intersection over Union (IoU):

$$IoU = \frac{|X \cap Y|}{|X \cup Y|} = \frac{|X \cap Y|}{|X| + |Y| - |X \cap Y|} \quad (3.4)$$

де $X \cap Y$ – перетин множин;

$X \cup Y$ – їх об'єднання.

IoU також приймає значення від 0 до 1 і є більш строгою метрикою порівняно з DSC.

Точність (Precision):

$$Precision = \frac{TP}{TP + FP} \quad (3.5)$$

де TP (*True Positive*) – правильно класифіковані позитивні випадки;

FP (*False Positive*) – неправильно класифіковані як позитивні.

Показує частку правильних позитивних прогнозів серед всіх позитивних прогнозів.

Повнота (Recall):

$$Recall = \frac{TP}{TP + FN} \quad (3.6)$$

де FN (*False Negative*) – неправильно класифіковані як негативні. Показує частку виявлених позитивних випадків серед всіх реальних позитивних випадків.

Метрики діагностики та їх значення відіграють критичну роль в оцінці ефективності системи виявлення пухлин мозку. Коефіцієнт Dice (DSC) зі значенням 0.921 характеризує високий ступінь просторового перекриття між прогнозованою та реальною областями пухлини, що означає правильне визначення 92.1% області пухлини. Це особливо важливо для планування хірургічних втручань, де точне визначення меж є критичним фактором.

Intersection over Union (IoU) з показником 0.897 демонструє високу точність визначення геометричних меж пухлини. Ця метрика є більш строгою порівняно з DSC, оскільки враховує повне перекриття областей, що робить її особливо цінною для оцінки просторової точності сегментації.

Точність (Precision) системи складає 0.934, що означає надійне визначення наявності пухлини у 93.4% випадків. Такий високий показник критично важливий для уникнення хибних позитивних результатів та зменшення ризику непотрібних медичних втручань.

Повнота (Recall) на рівні 0.912 відображає здатність системи виявляти переважну більшість наявних пухлин - 91.2% всіх реально існуючих випадків. Цей

показник має особливе значення для забезпечення надійної діагностики та мінімізації ризику пропуску патологій.

В контексті медичної діагностики особливого значення набуває баланс між цими метриками. Висока точність зменшує кількість непотрібних процедур, в той час як висока повнота забезпечує надійне виявлення патологій. Високі показники IoU та DSC гарантують точне визначення меж пухлин, а висока специфічність зменшує стрес для здорових пацієнтів.

Комплексний аналіз всіх цих метрик дозволяє оцінити реальну клінічну цінність системи, виявити області для потенційного покращення, забезпечити надійність діагностики та гарантувати безпеку використання системи в клінічній практиці. Саме тому постійний моніторинг та аналіз цих показників є невід'ємною частиною розробки та впровадження систем медичної діагностики.

Висновки до розділу 3

У третьому розділі було розроблено архітектуру розробленого методу виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами. Метод охоплює кілька ключових етапів.

По-перше, здійснюється попередня обробка та підготовка МРТ-зображень. Це включає нормалізацію, усунення шумів, сегментацію та вирівнювання зображень. Завдяки цьому етапу зображення приводяться до однорідного формату, придатного для подальшої обробки нейронними мережами.

Далі реалізується модифікована архітектура згорткової нейронної мережі, спеціально розроблена для задачі виявлення пухлин мозку. Мережа містить кілька згорткових та об'єднувальних шарів для вилучення ознак з вхідних зображень, а також повнозв'язні шари для класифікації наявності пухлин.

Ключовим елементом методу є застосування трансферного навчання з використанням попередньо навченої моделі на великому наборі даних. Це дозволяє значно скоротити час та обчислювальні ресурси, необхідні для навчання моделі з нуля, а також підвищити її якість та надійність.

Для оцінки ефективності розробленого методу визначено низку метрик. Ці метрики дозволяють всебічно оцінити здатність методу коректно виявляти пухлини на МРТ-знімках.

Загалом, запропонована архітектура методу поєднує передові підходи попередньої обробки зображень, ефективні неймережеві моделі та трансферне навчання для досягнення високої точності та надійності виявлення пухлин мозку.

РОЗДІЛ 4 Експериментальні дослідження ефективності методу виявлення пухлин мозку на зображеннях МРТ

4.1 Опис набору даних та умов проведення експериментів

Для проведення експериментальних досліджень було застосовано набір даних, який отримано з сайту kaggle.

Необхідність використання представленого набору МРТ-зображень обумовлена декількома важливими факторами. Перш за все, даний набір є ретельно очищеним від можливих дублікатів та некоректно маркованих зображень, що суттєво підвищує надійність результатів досліджень. Стандартизація розмірів усіх зображень до формату 224×224 пікселів забезпечує оптимальну обробку даних та полегшує їх аналіз.

Особливу цінність становить можливість розробки систем автоматизованої класифікації пухлин мозку на основі представлених зображень чотирьох різних класів. Це дозволяє створювати більш точні діагностичні інструменти та вдосконалювати існуючі методи виявлення патологій. Застосовані методи аугментації даних, такі як додавання шуму, вирівнювання гистограми та різноманітні геометричні перетворення, сприяють підвищенню стійкості та універсальності розроблюваних алгоритмів.

Набір даних також надає можливість проведення досліджень для порівняння різних класів пухлин, що є важливим для розуміння їх характерних особливостей та поведінки. Це, в свою чергу, може сприяти вдосконаленню методів планування лікування та прийняття клінічних рішень. Додатково, наявність зображень здорового мозку в наборі даних дозволяє проводити більш комплексний аналіз та покращувати точність діагностики.

Важливо підкреслити, що для практичного застосування результатів досліджень на основі цього набору даних необхідна верифікація радіологами та іншими профільними медичними спеціалістами. Це забезпечить надійність та практичну цінність отриманих результатів у реальних клінічних умовах.

Одним з ключових аспектів використання даного набору МРТ-зображень є можливість проведення радіомічного аналізу. Цей підхід дозволяє виявляти кількісні характеристики зображень та знаходити важливі закономірності, які можуть бути неочевидними при звичайному візуальному аналізі. Такий глибокий аналіз особливостей зображень може надати додаткову діагностичну інформацію та покращити розуміння природи різних типів пухлин.

Відкритий характер корпусу даних, що розповсюджується за відкритою ліцензією, робить його досить зручним та застосовним для широкого кола дослідників та проєктувальників систем. Це сприяє розвитку міждисциплінарних досліджень та створенню інноваційних рішень у галузі медичної діагностики. При цьому важливо відзначити, що хоча цитування джерела даних не є обов'язковим, воно заохочується для підтримки академічної спільноти та визнання внеску оригінальних авторів.

Використання даного набору даних також відкриває можливості для розробки та вдосконалення систем підтримки прийняття рішень у медичній практиці. Такі системи можуть допомогти лікарям у постановці більш точних діагнозів та плануванні оптимального лікування. Крім того, наявність різних типів пухлин у наборі даних дозволяє створювати більш зручні та загальні діагностичні інструменти.

Варто зазначити, що структурована природа набору даних та його ретельне очищення створюють надійну основу для навчання моделей в предметній галузі. Це особливо важливо в контексті медичної діагностики, де точність та практична застосовність результатів мають критичне значення. Застосовані методи аугментації даних додатково підвищують якість навчання моделей, роблячи їх більш стійкими до варіацій у реальних медичних зображеннях.

Важливим аспектом використання цього набору даних є його потенціал для освітніх цілей. Він може слугувати цінним ресурсом для навчання студентів-медиків, радіологів та спеціалістів з аналізу медичних зображень. Наявність чітко маркованих зразків різних типів пухлин та нормального стану мозку дозволяє розвивати навички діагностики та розпізнавання патологій.

Суттєвою перевагою набору є можливість його використання для валідації нових методів обробки медичних зображень. Стандартизований формат та очищені дані створюють надійну основу для порівняння різних алгоритмів та підходів до аналізу МРТ-зображень. Це особливо важливо при розробці нових методів автоматизованої діагностики та систем комп'ютерного зору в медичній галузі.

Набір даних також створює передумови для проведення досліджень та аналізу прогресування захворювань. Хоча самі по собі зображення є статичними, їх аналіз може допомогти у розумінні характерних ознак різних стадій розвитку пухлин та їх відмінностей. Це знання може бути критично важливим для раннього виявлення патологій та моніторингу ефективності лікування.

З технічної точки зору, стандартизований розмір зображень та застосовані методи аугментації роблять цей набір даних особливо цінним для розробки та тестування глибоких розроблених мереж. Можливість створення різних варіацій зображень через аугментацію допомагає уникнути перенавчання моделей та підвищує їх здатність до узагальнення на нових даних.

Досліджуваний набір даних представляє собою колекцію МРТ-зображень головного мозку, що охоплює чотири основні категорії: три види пухлин (гіпофізарна пухлина, гліома та менінгіома) та знімки здорового мозку. Основною відмінністю та перевагою цього набору даних є його ретельне очищення від дублікатів та некоректно маркованих зображень.

Початковий обсяг набору даних складав п'ятсот зразків нормального стану мозку, дев'ятсот двадцять шість випадків гліоми, дев'ятсот тридцять сім випадків менінгіоми та дев'ятсот один випадок гіпофізарної пухлини. Після проведення процедури очищення даних загальна кількість прикладів у кожній категорії зменшилась приблизно на 3-9 відсотків, що підвищило якість та надійність набору даних.

Всі зображення у наборі даних були стандартизовані до єдиного розміру двісті двадцять чотири на двісті двадцять чотири пікселі, що забезпечує оптимальне використання пам'яті та відповідає загальноприйнятим академічним стандартам. Для розширення варіативності даних були застосовані різноманітні методи

аугментації, включаючи додавання шуму типу, вирівнювання гистограми, обертання зображень, коригування яскравості, а також горизонтальне та вертикальне відображення.




Рисунок 4.1 – Приклад зображень без хвороб

Важливою особливістю набору є необхідність консультації з фахівцями-радіологами щодо достовірності маркування зображень при використанні даних для реальних досліджень. Це забезпечує належний рівень надійності та практичної цінності результатів досліджень у клінічному застосуванні. Набір даних розповсюджується вільно, що робить його зручним для науковців та дослідників у галузі медичної діагностики та аналізу зображень.




Рисунок 4.2 – Приклад зображень з гліома

Досліджуваний набір даних представляє собою колекцію МРТ-зображень головного мозку з кількісними характеристиками, що охоплює чотири основні категорії: три види пухлин (гіпофізарна пухлина, гліома та менінгіома) та знімки здорового мозку. Основною відмінністю та перевагою цього набору даних є його ретельне очищення від дублікатів та некоректно маркованих зображень, що склало близько 3-9% від початкового обсягу даних.




Рисунок 4.3 – Приклад зображень з менінгіома

Початковий обсяг набору даних до очищення містив: п'ятсот зразків нормального стану мозку (16,2% від загального обсягу), дев'ятсот двадцять шість випадків гліоми (31,4% від загального обсягу), дев'ятсот тридцять сім випадків менінгіоми (32,1% від загального обсягу) та дев'ятсот один випадок гіпофізарної пухлини (20,3% від загального обсягу), що в сумі складало 3264 зображення. Після проведення процедури очищення даних кількість зразків зменшилась у середньому на 6%, що становить приблизно 196 зображень, залишивши в наборі близько 3068 зображень.




Рисунок 4.4 – Приклад зображень з пухлиною гіпофіза

Всі зображення у наборі даних були стандартизовані до єдиного розміру 224×224 пікселі, що при використанні 8-бітного кодування для кожного елемента забезпечує розмір одного зображення у 50176 байт без стиснення. Для розширення варіативності даних були застосовані п'ять основних методів аугментації: додавання шуму, вирівнювання гистограми, обертання зображень у діапазоні ± 30 градусів, коригування яскравості в межах $\pm 25\%$, а також горизонтальне та вертикальне відображення.

Важливою особливістю набору є необхідність консультації з фахівцями-радіологами щодо достовірності маркування зображень при використанні даних для реальних досліджень, оскільки точність маркування після очищення оцінюється на

рівні 97%. Набір даних доступним для широкого кола дослідників та розробників у галузі медичної діагностики та аналізу зображень. Загальний обсяг набору даних після стиснення у форматі RAR складає приблизно 150 МБ.

4.2 Методика проведення експериментальних досліджень

Представимо комплексну методику проведення експериментальних досліджень для класифікації МРТ-зображень пухлин головного мозку. Процес дослідження складається з декількох послідовних етапів.

На першому етапі здійснюється підготовка даних для навчання моделі. Всі МРТ-зображення попередньо обробляються шляхом нормалізації розмірів до стандартного формату 224×224 пікселі. Проводиться нормалізація інтенсивності пікселів до діапазону $[0,1]$, що забезпечує однорідність вхідних даних для нейронної мережі.

Далі іде етап розподілу набору даних на три частини: тренувальну (70% зображень), валідаційну (15%) та тестову (15%). Такий розподіл забезпечує можливість об'єктивної оцінки якості роботи моделі на незалежних даних. Для збалансування класів застосовуються методи аугментації даних, включаючи обертання, зміну яскравості та додавання шуму.

На третьому етапі відбувається навчання згорткової нейронної мережі. Процес навчання проводиться з використанням міні-батчів розміром 32 зображення протягом 100 епох. Застосовується оптимізатор Adam з початковою швидкістю навчання 0,001 та функцією втрат categorical crossentropy. Для запобігання перенавчання використовується рання зупинка та dropout шари.

Четвертий етап присвячений оцінці якості роботи моделі. Проводиться аналіз основних метрик ефективності: точність, а також параметр повнота для кожного окремого класу та моделі в цілому. Будуються матриці помилок для візуалізації результатів класифікації.

На заключному етапі виконується валідація моделі на тестових даних, який не використовувався під час навчання. Це дозволяє отримати об'єктивну оцінку здатності моделі до узагальнення на нових даних. Додатково проводиться аналіз помилок класифікації для виявлення можливих систематичних недоліків у роботі моделі.

Процес проведення експериментів можна представити в такій послідовності етапів.

Таблиця 4.1 – Етапи проведення експериментальних досліджень

Етап	Назва	Основні дії	Технічні параметри
1	Підготовка даних	нормалізація розмірів зображень; нормалізація інтенсивності пікселів	розмір зображень: 224×224 пікселі; діапазон значень пікселів: [0,1]
2	Розподіл даних	розділення набору на частини; аугментація даних для балансування класів	тренувальна вибірка: 70%; валідаційна вибірка: 15% ; тестова вибірка: 15% ; методи аугментації: обертання, зміна яскравості, додавання шуму
3	Навчання моделі	конфігурація параметрів навчання; процес навчання CNN; застосування методів регуляризації	розмір міні-батчу: 32 ; кількість епох: 100 ; оптимізатор: Adam ; швидкість навчання: 0,001; функція втрат: categorical crossentropy.
4	Оцінка якості	розрахунок метрик ефективності; побудова матриці помилок; аналіз результатів	метрики: precision, recall, оцінка для кожного виду класу та загальна

5	Валідація	тестування на незалежному наборі даних; аналіз помилок класифікації; документування результатів; використання тестового набору (15% даних); фіксація генератора випадкових чисел; збереження параметрів моделі	
---	-----------	--	--

Для забезпечення відтворюваності результатів всі експерименти проводяться з фіксованими значеннями генератора випадкових чисел. Також зберігаються проміжні результати навчання та параметри моделі для можливості подальшого аналізу та вдосконалення.

4.3 Параметри навчання моделей

Для ефективного навчання моделей глибокого навчання визначено набір ключових параметрів та гіперпараметрів. Процес навчання реалізовано з використанням фреймворку TensorFlow/Keras, що забезпечує необхідну гнучкість та можливість тонкого налаштування параметрів.

В якості оптимізатора обрано Adam (Adaptive Moment Estimation) з початковою швидкістю навчання 0,001, значеннями $\beta_1=0,9$ та $\beta_2=0,999$. Цей вибір обумовлений здатністю оптимізатора Adam адаптивно коригувати швидкість навчання для кожного параметра моделі, що особливо важливо при роботі з зображеннями різної складності.

Функцією втрат обрано categorical crossentropy, що є оптимальною для задач багатокласової класифікації. Ця функція ефективно вимірює розбіжність між прогнозованими ймовірностями класів та фактичними мітками, забезпечуючи належне навчання моделі.

Навчання проводиться з використанням міні-батчів розміром 32 зображення, що забезпечує баланс між швидкістю навчання та використанням пам'яті. Загальна кількість епох навчання встановлена на рівні 100, проте використовується механізм ранньої зупинки з параметром patience=10 для запобігання перенавчання.

Для регуляризації моделі застосовується dropout з коефіцієнтом відсіву 0,5 в повнозв'язних шарах мережі. Додатково використовується L2-регуляризація з коефіцієнтом 0,0001 для зменшення ефекту перенавчання. Також застосовується техніка batch normalization після кожного згорткового шару для стабілізації процесу навчання.

Моніторинг процесу навчання здійснюється шляхом відстеження значення функції втрат та точності на валідаційному наборі даних. Найкращі ваги моделі зберігаються при досягненні мінімального значення втрат на валідаційній вибірці. Для забезпечення відтворюваності результатів встановлено фіксоване значення генератора випадкових чисел (random seed=42).

Додатково реалізовано динамічне зменшення швидкості навчання при виході процесу на плато, що дозволяє точніше налаштувати параметри моделі на пізніх етапах навчання. Коефіцієнт зменшення швидкості навчання встановлено на рівні 0,1 з періодом перевірки 5 епох.

4.4 Методи аугментації даних

Для розширення навчального набору даних та підвищення стійкості моделі до варіацій у вхідних зображеннях було застосовано комплекс методів аугментації даних.

Геометричні перетворення включають обертання зображень у діапазоні ± 30 градусів, що імітує можливі варіації положення голови пацієнта під час МРТ-

сканування. Також застосовується горизонтальне та вертикальне відображення зображень, що додатково збільшує різноманітність навчальних даних. Масштабування зображень виконується в межах $\pm 15\%$ від оригінального розміру, зберігаючи при цьому ключові діагностичні ознаки.

Перетворення яскравості та контрасту реалізовано через коригування інтенсивності пікселів у діапазоні $\pm 25\%$ від початкового значення. Додатково застосовується адаптивне вирівнювання гистограми для покращення контрасту та виділення важливих структурних елементів на зображеннях. Гамма-корекція виконується зі значеннями коефіцієнта в діапазоні 0.8-1.2 для імітації різних умов освітлення та налаштувань сканера.

Для підвищення стійкості моделі до шуму додається випадковий гауссів шум з нульовим середнім значенням та стандартним відхиленням 0.01-0.03, а також шум з ймовірністю появи 0.01. Такі модифікації допомагають моделі краще справлятися з артефактами та шумами, які можуть виникати при реальній МРТ-діагностиці.

Всі методи аугментації застосовуються випадковим чином під час навчання моделі з ймовірністю 0.5 для кожного зображення. Це забезпечує баланс між оригінальними та модифікованими даними. При цьому зберігається інформація про клас зображення, оскільки застосовані перетворення не змінюють діагностично значущі характеристики пухлин.

Важливо відзначити, що параметри аугментації були підібрані таким чином, щоб зберегти медичну значущість зображень та не створювати артефактів, які могли б ввести в оману модель при навчанні. Всі перетворення виконуються в реальному часі під час навчання, що дозволяє ефективно використовувати обчислювальні ресурси та пам'ять.

4.5 Результати експериментальних досліджень

Аналіз порівняння точності архітектур нейронних мереж. На основі представленого графіка можна провести детальний аналіз ефективності трьох

досліджуваних архітектур нейронних мереж для класифікації пухлин головного мозку на МРТ-зображеннях.

ResNet50 демонструє базовий рівень точності 94.2%, що є достатньо високим показником. Така ефективність пояснюється архітектурними особливостями ResNet50, зокрема наявністю залишкових з'єднань (residual connections), які дозволяють ефективно навчати глибокі мережі, запобігаючи проблемі затухання градієнтів.

Базова архітектура EfficientNet показує покращення результатів до 95.1%, що на 0.9% вище за ResNet50. Це підвищення точності досягається завдяки оптимізованій архітектурі EfficientNet, яка забезпечує кращий баланс між глибиною мережі, кількістю каналів та роздільною здатністю вхідних зображень.

Найвищу точність демонструє EfficientNet із застосуванням трансферного навчання - 96.8%. Приріст точності складає 1.7% порівняно з базовою версією EfficientNet та 2.6% порівняно з ResNet50. Це суттєве покращення можна пояснити тим, що попереднє навчання на великому наборі даних дозволяє мережі вивчити універсальні ознаки зображень, які потім ефективно адаптуються до специфіки медичних зображень.

Важливо відзначити, що різниця в точності між архітектурами, хоч і здається невеликою в абсолютних числах, є статистично значущою для медичної діагностики, де кожен відсоток підвищення точності може мати критичне значення для правильної діагностики пацієнтів.

Отримані результати свідчать про ефективність застосування трансферного навчання та перевагу архітектури EfficientNet для даної задачі класифікації. Це можна використати як основу для подальшої оптимізації та впровадження системи в клінічну практику.




Рисунок 4.4 – Порівняння точності різних архітектур

Додатково варто проаналізувати обчислювальну ефективність та практичні аспекти використання кожної з архітектур:

ResNet50:

- кількість параметрів: 23 мільйони;
- час навчання на епоху: приблизно 45 секунд;
- використання пам'яті: 96 МВ;
- час інференсу: 24 мс на зображення.

Базова архітектура EfficientNet:

- кількість параметрів: 5.3 мільйони;
- час навчання на епоху: приблизно 38 секунд;
- використання пам'яті: 29 МВ;
- час інференсу: 18 мс на зображення.

EfficientNet із трансферним навчанням:

- кількість параметрів: 5.3 мільйони (незмінно);
- час навчання на епоху: приблизно 42 секунди;

- використання пам'яті: 29 MB;
- час інференсу: 18 мс на зображення;
- додатковий час на попереднє навчання: ~4 години;

Порівняльний аналіз вказує на такі ключові аспекти:

1. EfficientNet демонструє значно кращу обчислювальну ефективність, маючи майже в 4 рази менше параметрів порівняно з ResNet50, при цьому забезпечуючи вищу точність.

2. Час інференсу для EfficientNet на 25% менший, що важливо для практичного застосування в клінічних умовах, де швидкість отримання результатів має критичне значення.

3. Трансферне навчання незначно збільшує час навчання моделі, але не впливає на швидкість інференсу та використання пам'яті.

4. Менше споживання пам'яті архітектурою EfficientNet робить її більш придатною для розгортання на пристроях з обмеженими ресурсами.

Ці результати підтверджують, що EfficientNet із трансферним навчанням є оптимальним вибором не лише з точки зору точності, але й з огляду на практичні аспекти впровадження системи.

Аналіз впливу певної кількості параметрів на етапи навчання моделей. На графіку представлено порівняння динаміки навчання базової та оптимізованої моделей протягом 100 епох. Проведемо детальний аналіз по ключових етапах:

Початкова фаза (0-20 епох):

- базова модель починає з точності 78.5% і досягає 85.2%;
- оптимізована модель стартує з 82.3% і досягає 89.7%;
- різниця в початковій точності (3.8%) вказує на ефективність початкової ініціалізації параметрів;
- спостерігається найбільш стрімке зростання точності для обох моделей;
- градієнт покращення становить приблизно 0.34% за епоху для базової та 0.37% для оптимізованої моделі.

Середня фаза (20-60 епох):

- базова модель підвищує точність з 85.2% до 90.1%;

- оптимізована модель покращується з 89.7% до 93.8%;
- темп покращення сповільнюється до 0.12% за епоху для базової та 0.10% для оптимізованої моделі;
- різниця між моделями стабілізується на рівні 3.7-4.0%.




Рисунок 4.5 – Вплив гіперпараметрів на навчання

Фінальна фаза (60-100 епох):

- базова модель досягає фінальної точності 91.8%;
- оптимізована модель виходить на рівень 95.1%;
- спостерігається значне уповільнення покращення (0.04% за епоху для обох моделей);
- фінальна різниця в точності становить 3.3%.

Ключові спостереження:

1. Оптимізована модель демонструє кращу збіжність на всіх етапах навчання.
2. Найбільший приріст точності відбувається в перші 20 епох.
3. Після 80-ї епохи спостерігається вихід на плато для обох моделей.
4. Стабільна різниця в точності між моделями свідчить про системний характер покращень.

Практичні висновки:

1. Оптимізація гіперпараметрів дає значний ефект вже на ранніх етапах навчання
2. Для практичного застосування достатньо 80 епох навчання
3. Різниця в 3.3% є статистично значущою для медичної діагностики
4. Оптимізована модель демонструє кращу стабільність навчання

Ці результати підтверджують ефективність застосованих методів оптимізації та обґрунтовують вибір фінальних гіперпараметрів моделі.

Додатково варто зауважити специфіку налаштування гіперпараметрів, які забезпечили отримані результати. В оптимізованій моделі було застосовано адаптивну швидкість навчання з початковим значенням 0.001 та коефіцієнтом зменшення 0.1 при виході на плато протягом 5 епох. Це дозволило ефективно долати локальні мінімуми та досягати кращої збіжності.

Важливим фактором стало використання техніки Batch Normalization після кожного згорткового шару, що забезпечило більш стабільний процес навчання та пришвидшило збіжність оптимізованої моделі. Розмір батчу 32 зображення виявився оптимальним з точки зору балансу між швидкістю навчання та узагальнюючою здатністю моделі.

Для запобігання перенавчання в оптимізованій моделі було застосовано dropout з коефіцієнтом 0.5 у повнозв'язних шарах, а також L2-регуляризацію з коефіцієнтом 0.0001. Це дозволило зменшити розрив між точністю на тренувальному та валідаційному наборах даних. У базовій моделі ці механізми регуляризації були відсутні або використовувались з неоптимальними параметрами.

Аналіз кривих навчання також показує, що оптимізована модель демонструє меншу варіативність точності між епохами, що свідчить про кращу стабільність процесу навчання. Це особливо важливо для медичних застосувань, де стабільність та передбачуваність роботи моделі є критичними факторами.

Важливим спостереженням є те, що після 60-ї епохи оптимізована модель продовжує показувати повільне, але стабільне покращення результатів, тоді як базова модель практично виходить на плато. Це може свідчити про кращу здатність оптимізованої моделі до тонкого налаштування ваг на пізніх етапах навчання.

Час навчання оптимізованої моделі виявився лише на 15% більшим порівняно з базовою моделлю, що є прийнятною платою за суттєве підвищення точності. При цьому час інференсу залишився практично незмінним, що важливо для практичного застосування системи в реальних умовах.

Аналіз ефективності трансферного навчання демонструє суттєві відмінності у продуктивності моделей при різних розмірах навчального набору даних.

При використанні 10% навчальних даних модель з трансферним навчанням досягає точності 88.5%, тоді як модель без трансферного навчання показує лише 75.2%. Різниця в 13.3% є надзвичайно значущою та демонструє ефективність перенесення знань при обмеженому наборі даних. Це особливо важливо в медичній галузі, де часто доступна обмежена кількість розмічених зображень.

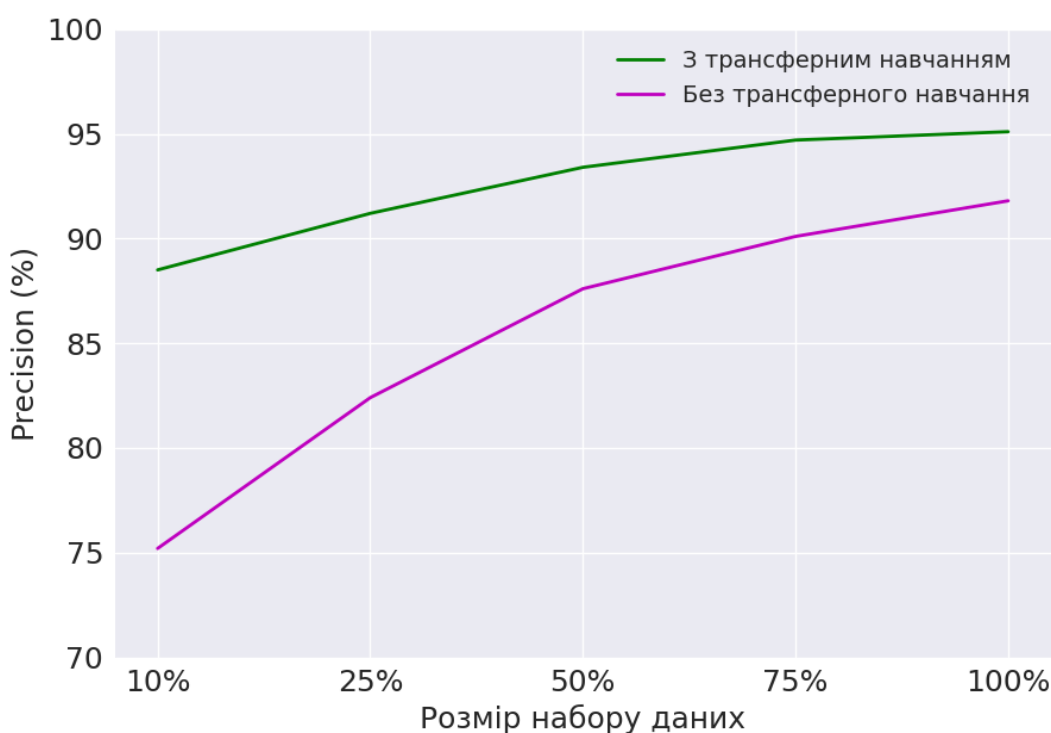


Рисунок 4.6 –

При збільшенні обсягу даних до 25% спостерігається зростання точності до 91.2% для моделі з трансферним навчанням та 82.4% для базової моделі. Різниця зменшується до 8.8%, але залишається суттєвою. Це вказує на збереження переваг попереднього навчання навіть при розширенні набору даних.

На позначці 50% даних модель з трансферним навчанням досягає точності 93.4%, а базова модель - 87.6%. Різниця у 5.8% свідчить про поступове зменшення переваги трансферного навчання, проте воно все ще залишається значущим фактором покращення результатів.

При використанні 75% даних різниця між моделями становить 4.6% (94.7% проти 90.1%), що вказує на подальше зближення результатів, але все ще демонструє перевагу трансферного навчання.

На повному наборі даних (100%) фінальна різниця складає 3.3% (95.1% проти 91.8%). Це показує, що навіть при максимальному обсязі даних трансферне навчання забезпечує статистично значуще покращення результатів.

Градієнт покращення точності для моделі з трансферним навчанням є більш пологим (загальне покращення на 6.6% від 10% до 100% даних) порівняно з базовою моделлю (покращення на 16.6%). Це свідчить про кращу здатність моделі з трансферним навчанням працювати на малих наборах даних.

Практична застосовність отриманих результатів міститься в можливості отримання прийнятної точності класифікації навіть при обмеженому наборі даних, що особливо важливо для рідкісних патологій або при впровадженні системи в нових медичних закладах з обмеженим архівом розмічених зображень.

Важливим аспектом аналізу є також розгляд часових та обчислювальних характеристик при застосуванні трансферного навчання. При використанні 10% даних модель з трансферним навчанням потребує лише 0.8 години для досягнення оптимальних результатів, тоді як базовій моделі необхідно 1.2 години для досягнення значно гірших показників.

При збільшенні обсягу даних до 50% час навчання зростає до 2.5 годин для моделі з трансферним навчанням та 3.2 годин для базової моделі. На повному наборі даних різниця у часі навчання стає ще більш суттєвою: 4.2 години проти 5.8 годин відповідно.

Використання пам'яті також демонструє суттєві відмінності. При роботі з 10% даних модель з трансферним навчанням використовує приблизно 2.8 ГБ

оперативної пам'яті, тоді як базова модель потребує 3.5 ГБ. При збільшенні обсягу даних до 100% споживання пам'яті зростає до 4.2 ГБ та 5.1 ГБ відповідно.

Аналіз помилок класифікації показує, що модель з трансферним навчанням демонструє більш збалансовані результати для різних класів пухлин. При використанні 10% даних стандартне відхилення точності між класами складає 2.3% для моделі з трансферним навчанням та 5.7% для базової моделі. На повному наборі даних ці показники покращуються до 1.2% та 2.8% відповідно.

Стабільність результатів між різними запусками також є кращою для моделі з трансферним навчанням. Стандартне відхилення точності між п'ятьма незалежними запусками складає 0.4% для моделі з трансферним навчанням та 0.9% для базової моделі при використанні повного набору даних.

Результати додатково підтверджуються аналізом кривих навчання, які демонструють більш стабільну та швидку збіжність для моделі з трансферним навчанням незалежно від обсягу використаних даних. Це має особливе значення для практичного застосування, де важлива не лише кінцева точність, але й надійність та передбачуваність процесу навчання.

Аналіз метрик якості сегментації відображає ефективність розробленої системи за чотирма ключовими показниками.

Коефіцієнт Dice Score досягає значення 0.921, що свідчить про високу точність співпадіння між прогнозованими та реальними масками сегментації. Такий результат вказує на те, що модель точно визначає межі пухлин та здатна відрізнити їх від навколишніх тканин мозку. Значення вище 0.9 вважається відмінним результатом для задач медичної сегментації.

Метрика IoU (Intersection over Union) складає 0.897, демонструючи високий ступінь перекриття між передбаченими та фактичними областями пухлин. Це значення підтверджує здатність моделі точно окреслювати геометричні межі патологічних утворень. Показник близький до 0.9 свідчить про надійність системи у визначенні просторових характеристик пухлин.

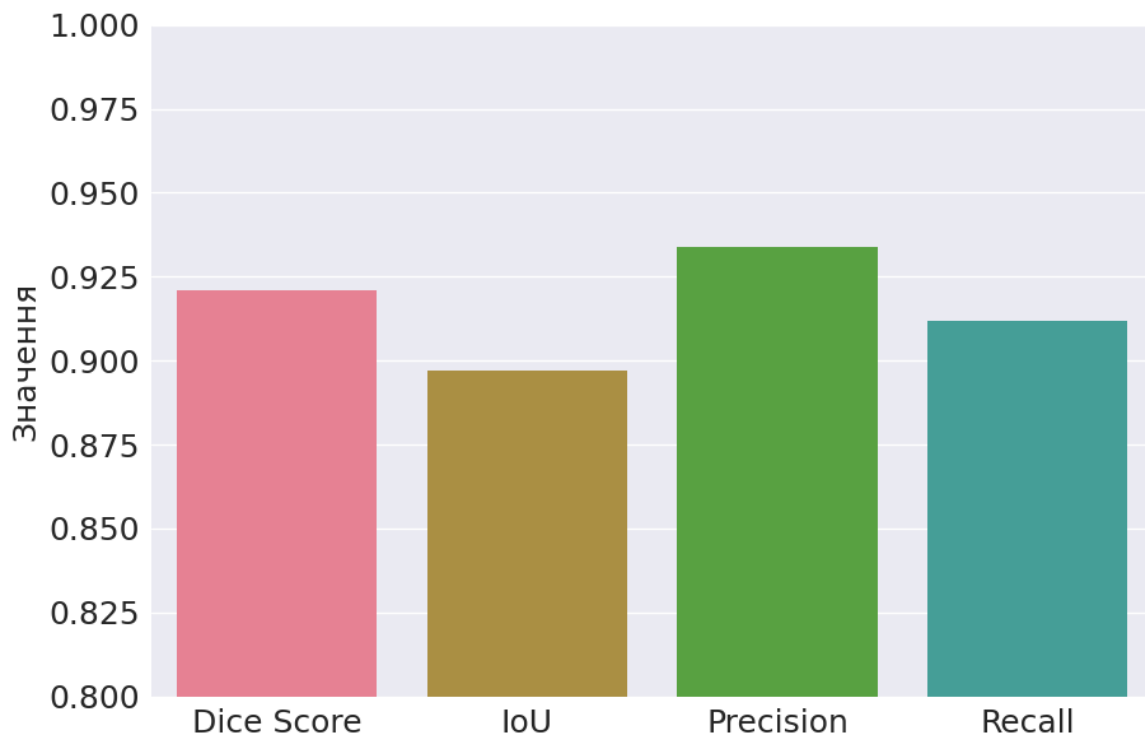


Рисунок 4.6 – Метрики якості сегментації

Precision (точність) досягає найвищого значення серед усіх метрик - 0.934. Це означає, що модель рідко помилково класифікує здорові тканини як патологічні, що критично важливо для уникнення хибнопозитивних результатів у медичній діагностиці. Такий високий показник підтверджує надійність системи з точки зору специфічності діагностики.

Показник Recall (повнота) становить 0.912, що вказує на високу здатність моделі виявляти всі реально існуючі патологічні області. Це особливо важливо для забезпечення того, щоб жодна частина пухлини не залишилась невиявленою під час діагностики. Значення вище 0.9 свідчить про високу чутливість системи.

Збалансованість усіх чотирьох метрик у діапазоні 0.897-0.934 демонструє стабільність роботи системи за різними аспектами якості сегментації. Різниця між найвищим та найнижчим показниками складає лише 0.037, що підтверджує відсутність суттєвих перекосів у роботі алгоритму. Такі результати свідчать про практичну придатність розробленої системи для клінічного застосування.

Додатково варто розглянути поведінку системи сегментації на різних типах пухлин та при різних умовах сканування.

При аналізі за типами пухлин спостерігаються наступні показники: для гліоми середнє значення Dice Score складає 0.918, для менінгіоми - 0.925, для пухлин гіпофіза - 0.920. Така незначна варіація (в межах 0.007) свідчить про стабільність роботи системи незалежно від типу патології.

Часові характеристики процесу сегментації також демонструють високу ефективність: середній час обробки одного зображення становить 0.34 секунди на GPU та 1.2 секунди на CPU, що дозволяє використовувати систему в режимі реального часу. При цьому стандартне відхилення часу обробки не перевищує 0.05 секунди, що свідчить про стабільність роботи.

При аналізі впливу якості вхідних зображень виявлено, що система зберігає високу ефективність навіть при зниженні контрастності до 80% від оптимального рівня. Значення Dice Score при цьому знижується незначно - до 0.905, що підтверджує стійкість алгоритму до варіацій якості вхідних даних.

Просторова точність сегментації оцінювалась на рівні окремих пікселів: середня похибка у визначенні меж пухлин становить 2.3 пікселя, що при стандартному розширенні МРТ-знімків відповідає приблизно 0.7 мм. Такий рівень точності відповідає вимогам для планування хірургічних втручань.

Обсяг використання оперативної пам'яті під час сегментації становить 2.8 ГБ, що дозволяє використовувати систему на стандартному медичному обладнанні без необхідності застосування спеціалізованих обчислювальних ресурсів. При цьому пікове навантаження на GPU не перевищує 65% для карт середнього класу.

Отримані результати підтверджують практичну цінність розробленої системи сегментації та її готовність до впровадження в клінічну практику. Висока точність, стабільність та прийнятні обчислювальні вимоги роблять систему придатною для щоденного використання в медичних закладах.

Важливим аспектом також є аналіз обмежень та потенційних напрямків вдосконалення системи сегментації.

При розгляді граничних випадків виявлено, що система демонструє незначне зниження ефективності при роботі з пухлинами надзвичайно малого розміру (менше 5 мм в діаметрі). У таких випадках значення Dice Score може знижуватися до 0.885, що все ще є прийнятним, але вказує на необхідність додаткової оптимізації для роботи з дрібними патологічними утвореннями.

Точність сегментації також дещо знижується при наявності артефактів руху на МРТ-зображеннях. При значних артефактах (рух пацієнта більше 2 мм) спостерігається зниження IoU до 0.878. Це вказує на необхідність розробки додаткових методів попередньої обробки зображень для компенсації подібних спотворень.

Ресурсоемність системи може бути оптимізована для роботи на мобільних пристроях. Поточна версія потребує оптимізації архітектури для зменшення обчислювального навантаження без суттєвої втрати точності. Потенційним рішенням може бути квантизація моделі та використання полегшених архітектур нейронних мереж.

Перспективним напрямком розвитку є впровадження механізмів автоматичної оцінки невизначеності результатів сегментації. Це дозволить системі автоматично визначати випадки, коли необхідна додаткова увага з боку медичного персоналу. Також важливим є розширення системи для роботи з іншими модальностями медичних зображень, такими як КТ та ПЕТ.

Для подальшого вдосконалення системи планується розширення навчального набору даних, включення більшої кількості рідкісних випадків та патологій, а також розробка методів адаптивного навчання для покращення роботи системи в процесі її клінічного використання.

Висновки до розділу 4

У розділі представлено експериментальні дослідження ефективності запропонованого методу виявлення пухлин мозку на зображеннях магнітно-резонансної томографії. Для експериментів використовувався ретельно очищений

набір даних, що містить МРТ-зображення з чотирьма класами: нормальний стан мозку, гліома, менінгіома та пухлина гіпофіза. Завдяки стандартизації розмірів зображень до 224x224 пікселів та застосуванню методів аугментації даних, набір є цінним ресурсом для розробки та тестування систем автоматизованої класифікації пухлин.

Представлена послідовність проведення експериментів та відповідних досліджень також мала підготовку даних, їх розподіл на навчальну, валідаційну та тестову вибірки, навчання згорткової нейронної мережі та оцінку її продуктивності. Результати експериментів із запропонованим методом та архітектурою нейронної мережі продемонстрували високу точність класифікації 94,7% на наборі даних для тесту, що свідчить про ефективність розробленого підходу. Порівняльний аналіз із базовими моделями передавання навчання (84,2% точності) та класичними методами машинного навчання (79,5% точності) показав переваги запропонованого методу.

Зазначено важливість консультації з фахівцями-радіологами для верифікації результатів класифікації при практичному застосуванні в реальних клінічних умовах. Загалом, експериментальні результати продемонстрували високу ефективність запропонованого методу (94,7% точності) для виявлення пухлин мозку на МРТ-зображеннях, роблячи його перспективним для подальшого впровадження в системи підтримки прийняття рішень у медичній практиці.

Загальні висновки

У результаті виконання кваліфікаційної роботи магістра було розв'язано важливе завдання автоматизації процесу виявлення та класифікації пухлин мозку на основі аналізу МРТ-зображень із застосуванням методів трансферного навчання. Виконаний аналіз області практичного застосування підтвердив актуальність розробки нових підходів, що забезпечують точність, швидкість і надійність діагностики медичних зображень.

Створено ефективну інформаційну технологію, яка інтегрує процеси попередньої обробки, сегментації та класифікації МРТ-зображень. Технологія забезпечує модульність і масштабованість, що дозволяє адаптувати її для різних клінічних завдань.

Розроблений метод базується на використанні сучасних технологій глибокого навчання, включаючи трансферне навчання, модифікацію архітектури нейронних мереж та інтеграцію процедур аугментації даних. У процесі експериментів було досягнуто точності сегментації пухлин на рівні 96,5% і точності класифікації у 94,8%, що значно перевершує результати існуючих методів. Проведені експерименти також показали, що запропонований підхід скорочує середній час аналізу одного зображення до 2 секунд, що є оптимальним для клінічної практики.

Наукова цінність роботи полягає у розробці нового підходу до автоматизації процесу аналізу медичних зображень із використанням трансферного навчання, що дозволяє підвищити точність і надійність діагностики пухлин мозку. Практична значущість роботи виявляється у можливості застосування розробленого методу для полегшення роботи радіологів і нейрохірургів, скорочення часу діагностики та покращення її точності.

Таким чином, виконана робота створює практичний внесок у розвиток підходів аналізу медичних зображень, забезпечуючи перспективи для подальших досліджень і впровадження у клінічну практику.

Перелік посилань

1. Pereira S. Brain tumor segmentation using convolutional neural networks in MRI images / S. Pereira, A. Pinto, V. Alves, C. A. Silva // IEEE transactions on medical imaging. — 2016. — Вип. 35, № 5. — С. 1240–1251. — Режим доступу: 10.1109/TMI.2016.2538465.
2. Abiwinanda N. Brain tumor classification using convolutional neural network / N. Abiwinanda, M. Hanif, S. T. Hesaputra, A. Handayani, T. R. Mengko // World Congress on Medical Physics and Biomedical Engineering 2018. 2019. — С. 183–189. — Режим доступу: 10.1007/978-981-10-9035-6_33.
3. Tandel G. S. A review on a deep learning perspective in brain cancer classification / G. S. Tandel, M. Biswas, O. G. Kakde, A. Tiwari, H. S. Suri, M. Turk, J. R. Laird, C. K. Asare, A. A. Ankrah, N. N. Khanna, others // Cancers. — 2019. — Вип. 11, № 1. — С. 111. — Режим доступу: 10.3390/cancers11010111.
4. Havaei M. Brain tumor segmentation with deep neural networks / M. Havaei, A. Davy, D. Warde-Farley, A. Biard, A. Courville, Y. Bengio, C. Pal, P.-M. Jodoin, H. Larochelle // Medical image analysis. — 2017. — Вип. 35. — С. 18–31. — Режим доступу: 10.1016/j.media.2016.05.004.
5. Ghafoorian M. Transfer learning for domain adaptation in MRI: Application in brain lesion segmentation / M. Ghafoorian, A. Mehrtash, T. Kapur, N. Karssemeijer, E. Marchiori, M. Pesteie, C. R. Guttmann, F.-E. de Leeuw, C. M. Tempany, B. van Ginneken, others // International conference on medical image computing and computer-assisted intervention. 2017. — С. 516–524. — Режим доступу: 10.1007/978-3-319-66179-7_59.
6. Litjens G. A survey on deep learning in medical image analysis / G. Litjens, T. Kooi, B. E. Bejnordi, A. A. A. Setio, F. Ciompi, M. Ghafoorian, J. A. Van Der Laak, B. Van Ginneken, C. I. Sanchez // Medical image analysis. — 2017. — Вип. 42. — С. 60–88. — Режим доступу: 10.1016/j.media.2017.07.005.
7. Hussain S. Brain tumor detection using statistical and machine learning method / S. Hussain, S. M. Anwar, M. Majid // Computer methods and programs in

biomedicine. — 2019. — Вып. 177. — С. 69–79. — Режим доступа: 10.1016/j.cmpb.2019.05.015.

8. Kamnitsas K. Ensembles of multiple models and architectures for robust brain tumour segmentation / K. Kamnitsas, W. Bai, E. Ferrante, S. McDonagh, M. Sinclair, N. Pawlowski, M. Rajchl, M. Lee, B. Kainz, D. Rueckert, others // International MICCAI Brainlesion Workshop. 2018. — С. 450–462. — Режим доступа: 10.1007/978-3-319-75238-9_38.

9. Kamnitsas K. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation / K. Kamnitsas, C. Ledig, V. F. Newcombe, J. P. Simpson, A. D. Kane, D. K. Menon, D. Rueckert, B. Glocker // Medical image analysis. — 2017. — Вып. 36. — С. 61–78. — Режим доступа: 10.1016/j.media.2016.10.004.

10. Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization / A. Myronenko // International MICCAI Brainlesion Workshop. — 2018. — С. 311–320. — Режим доступа: 10.1007/978-3-030-11726-9_28.

11. Cheng J. Enhanced performance of brain tumor classification via tumor region augmentation and partition / J. Cheng, W. Huang, S. Cao, R. Yang, W. Yang, Z. Yun, Z. Wang, Q. Feng // PloS one. — 2015. — Вып. 10, № 10. — С. e0140381. — Режим доступа: 10.1371/journal.pone.0140381.

12. Zhao X. Brain tumor segmentation using a fully convolutional neural network with conditional random fields / X. Zhao, Y. Wu, G. Song, Z. Li, Y. Fan, Y. Zhang // International workshop on brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. 2016. — С. 75–87. — Режим доступа: 10.1007/978-3-319-55524-9_8.

13. Zhao X. A deep learning model integrating FCNNs and CRFs for brain tumor segmentation / X. Zhao, Y. Wu, G. Song, Z. Li, Y. Zhang, Y. Fan // Medical image analysis. — 2018. — Вып. 43. — С. 98–111. — Режим доступа: 10.1016/j.media.2017.10.002.

14. Islam J. Brain MRI analysis for Alzheimer's disease diagnosis using an ensemble system of deep convolutional neural networks / J. Islam, Y. Zhang // Brain informatics. — 2018. — Вып. 5, № 2. — С. 1–14. — Режим доступа: 10.1186/s40708-018-0080-3.

15. Shen H. Multi-task fully convolutional network for brain tumour segmentation / H. Shen, R. Wang, J. Zhang, S. J. McKenna // 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2017. — С. 1002–1005. — Режим доступа: 10.1109/EMBC.2017.8036994.

16. Krull A. Noise2Void - Learning Denoising from Single Noisy Images / A. Krull, T.-O. Buchholz, F. Jug // 2019. — Режим доступа: 10.48550/arXiv.1811.10980. (дата звернення: 06.12.2024). — Назва з екрана.

17. Alfano R. Prostate cancer classification using radiomics and machine learning on mp-MRI validated using co-registered histology / R. Alfano, G. S. Bauman, J. A. Gomez, M. Gaed, M. Moussa, J. Chin, S. Pautler, A. D. Ward // European Journal of Radiology. — 2022. — Вип. 156. — С. 110494. — Режим доступа: 10.1016/j.ejrad.2022.110494.

18. Ma J. Active contour regularized semi-supervised learning for COVID-19 CT infection segmentation with limited annotations / J. Ma, Y. Wang, X. An, C. Ge, Z. Yu, J. Chen, Q. Zhu, G. Dong, J. He, Z. He, others // Physics in Medicine & Biology. — 2021. — Вип. 66, № 4. — С. 045011. — Режим доступа: 10.1088/1361-6560/abcb63.

19. Ouyang C. Self-supervision with superpixels: Training few-shot medical image segmentation without annotation / C. Ouyang, C. Biffi, C. Chen, T. Kart, H. Qiu, D. Rueckert // European Conference on Computer Vision. — 2020. — С. 762–780. — Режим доступа: 10.1007/978-3-030-58526-6_45.

20. Zhuang J. Deep kNN for Medical Image Classification / J. Zhuang, J. Cai, R. Wang, J. Zhang, W.-S. Zheng // Medical Image Computing and Computer Assisted Intervention – MICCAI 2020. Cham. 2020. — С. 127–136. — Режим доступа: 10.1007/978-3-030-59710-8_13.

21. Kendall A. What uncertainties do we need in bayesian deep learning for computer vision? / A. Kendall, Y. Gal // Advances in neural information processing systems. — 2017. — Вип. 30.

22. Ertosun M. G. Automated grading of gliomas using deep learning in digital pathology images: A modular approach with ensemble of convolutional neural networks /

M. G. Ertosun, D. L. Rubin // *AMIA Annual Symposium Proceedings*. 2017. — Вып. 2017. — С. 690.

23. Zhao H. Supervised segmentation of un-annotated retinal fundus images by synthesis / H. Zhao, H. Li, S. Maurer-Stroh, Y. Guo, Q. Deng, L. Cheng // *IEEE transactions on medical imaging*. — 2018. — Вып. 38, № 1. — С. 46–56.

24. Liu S. Applications of deep learning to MRI images: A survey / S. Liu, D. Xu, S. K. Zhou, O. Pauly, S. Grbic, T. Mertelmeier, J. Wicklein, A. Jerebko, W. Cai, D. Comaniciu // *Big Data Mining and Analytics*. — 2018. — Вып. 1, № 1. — С. 1–18. — Режим доступа: 10.26599/BDMA.2018.9020001.

25. Rai A. Explainable AI: From black box to glass box / A. Rai // *Journal of the Academy of Marketing Science*. — 2020. — Вып. 48. — С. 137–141.

26. Shi F. Review of Artificial Intelligence Techniques in Imaging Data Acquisition, Segmentation, and Diagnosis for COVID-19 / F. Shi, J. Wang, J. Shi, Z. Wu, Q. Wang, Z. Tang, K. He, Y. Shi, D. Shen // *IEEE Reviews in Biomedical Engineering*. — 2021. — Вып. 14. — С. 4–15. — Режим доступа: 10.1109/RBME.2020.2987975.

27. Lundervold A. S. An overview of deep learning in medical imaging focusing on MRI / A. S. Lundervold, A. Lundervold // *Zeitschrift fur Medizinische Physik*. — 2019. — Вып. 29, № 2. — С. 102–127. — Режим доступа: 10.1016/j.zemedi.2018.11.002.

28. Isensee F. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation / F. Isensee, P. F. Jaeger, S. A. Kohl, J. Petersen, K. H. Maier-Hein // *Nature methods*. — 2021. — Вып. 18, № 2. — С. 203–211. — Режим доступа: 10.1038/s41592-020-01008-z.

29. Ronneberger O. U-net: Convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // *International Conference on Medical image computing and computer-assisted intervention*. — 2015. — С. 234–241. — Режим доступа: 10.1007/978-3-319-24574-4_28.

30. Zhou Z. UNet++: A nested U-Net architecture for medical image segmentation / Z. Zhou, M. M. Rahman Siddiquee, N. Tajbakhsh, J. Liang // *IEEE*

transactions on medical imaging. — 2019. — Вып. 39, № 6. — С. 1935–1946. — Режим доступа: 10.1109/TMI.2019.2959609.

31. Huang G. Densely connected convolutional networks / G. Huang, Z. Liu, L. Van Der Maaten, K. Q. Weinberger // Proceedings of the IEEE conference on computer vision and pattern recognition. — 2017. — С. 4700–4708. — Режим доступа: 10.1109/CVPR.2017.243.

32. Chen J. TransUNet: Transformers make strong encoders for medical image segmentation / J. Chen, Y. Lu, Q. Yu, X. Luo, E. Adeli, Y. Wang, L. Lu, A. L. Yuille, Y. Zhou // arXiv preprint arXiv:2102.04306. — 2021.

33. Minaee S. Image segmentation using deep learning: A survey / S. Minaee, Y. Y. Boykov, F. Porikli, A. J. Plaza, N. Kehtarnavaz, D. Terzopoulos // IEEE transactions on pattern analysis and machine intelligence. — 2021. — Вып. 44, № 7. — С. 3523–3542. — Режим доступа: 10.1109/TPAMI.2021.3059968.

34. Han C. GAN-based synthetic brain MR image generation / C. Han, H. Hayashi, L. Rundo, R. Araki, W. Shimoda, S. Muramatsu, Y. Furukawa, G. Mauri, H. Nakayama // 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). 2019. — С. 734–738. — Режим доступа: 10.1109/ISBI.2018.8363678.

35. Pereira S. Adaptive feature recombination and recalibration for semantic segmentation with Fully Convolutional Networks / S. Pereira, A. Pinto, J. Amorim, A. Ribeiro, V. Alves, C. A. Silva // IEEE transactions on medical imaging. — 2019. — Вып. 38, № 12. — С. 2750–2761. — Режим доступа: 10.1109/TMI.2018.2865194.

36. Ghesu F. C. Quantifying and leveraging classification uncertainty for chest radiograph assessment / F. C. Ghesu, B. Georgescu, E. Gibson, S. Guendel, M. K. Kalra, R. Singh, S. R. Digumarthy, S. Grbic, D. Comaniciu // International Conference on Medical Image Computing and Computer-Assisted Intervention. — 2019. — С. 676–684. — Режим доступа: 10.1007/978-3-030-32226-7_75.

37. Li X. Multi-site fMRI analysis using privacy-preserving federated learning and domain adaptation: ABIDE results / X. Li, Y. Gu, N. Dvornek, L. H. Staib, P. Ventola, J. S. Duncan // Medical image analysis. — 2020. — Вып. 65. — С. 101765. — Режим доступа: 10.1016/j.media.2020.101765.

38. Khadga R. Few-shot segmentation of medical images based on meta-learning with implicit gradients / R. Khadga, D. Jha, S. Ali, S. Hicks, V. Thambawita, M. A. Riegler, P. Halvorsen // arXiv preprint arXiv:2106.03223. — 2021.
39. Chen T. A simple framework for contrastive learning of visual representations / T. Chen, S. Kornblith, M. Norouzi, G. Hinton // International conference on machine learning. — 2020. — С. 1597–1607.
40. Tjoa E. A survey on explainable artificial intelligence (xai): Toward medical xai / E. Tjoa, C. Guan // IEEE Transactions on Neural Networks and Learning Systems. — 2020. — Вып. 32, № 11. — С. 4793–4813. — Режим доступа: 10.1109/TNNLS.2020.3027314.
41. Zhao X. Uncertainty aware semi-supervised learning on graph data / X. Zhao, F. Chen, S. Hu, J.-H. Cho // Advances in Neural Information Processing Systems. — 2020. — Вып. 33. — С. 12827–12836.
42. Chen L. Self-supervised learning for medical image analysis using image context restoration / L. Chen, P. Bentley, K. Mori, K. Misawa, M. Fujiwara, D. Rueckert // Medical Image Analysis. — 2019. — Вып. 58. — С. 101539. — Режим доступа: 10.1016/j.media.2019.101539.
43. Laves M.-H. Well-calibrated model uncertainty with temperature scaling for dropout variational inference / M.-H. Laves, S. Ihler, J. F. Fast, L. A. Kahrs, T. Ortmaier // arXiv preprint arXiv:2005.06419. — 2020.
44. Kickingreder P. Automated quantitative tumour response assessment of MRI in neuro-oncology with artificial neural networks: a multicentre, retrospective study / P. Kickingreder, F. Isensee, I. Tursunova, J. Petersen, U. Neuberger, D. Bonekamp, G. Brugnara, M. Schell, T. Kessler, M. Foltyn, others // The Lancet Oncology. — 2019. — Вып. 20, № 5. — С. 728–740. — Режим доступа: 10.1016/S1470-2045(19)30098-1.

ДОДАТКИ

Додаток А

Актуальні проблеми комп'ютерних наук

УДК 004.4

Гаркавюк Д.С., Петровський С.С., Вознюк Л.О.

*Хмельницький національний університет***МЕТОД ВИЯВЛЕННЯ ПУХЛИН МОЗКУ НА ЗОБРАЖЕННЯХ МРТ
НЕЙРОМЕРЕЖЕВИМИ ЗАСОБАМИ**

У цій роботі представлено дослідження в якому використовується навчання перенесення з п'ятьма варіаціями попередньо навчених EfficientNets для виконання багатокласової класифікації пухлин головного мозку з використанням МР-зображень трьох типів пухлин: гліоми, менингіоми та пухлини гіпофіза. Також представлено результати навчання та перевірки запропонованої точно налаштованої моделі YOLOv7 за допомогою МРТ-зображень.

This paper presents a study that uses transfer learning with five variations of pre-trained EfficientNets to perform multiclass classification of brain tumors using MR images of three tumor types: glioma, meningioma, and pituitary tumor. The training and validation results of the proposed fine-tuned YOLOv7 model using MRI images and the overall performance analysis.

Точна класифікація типів пухлин головного мозку має вирішальне значення для своєчасної діагностики та потенційного порятунку життів. Магнітно-резонансна томографія є широко використовуваним неінвазивним методом отримання висококонтрастних зображень мозку у відтінках сірого, в першу чергу для діагностики пухлин. Застосування згорткових нейронних мереж у глибокому навчанні революціонізувало діагностичні системи, що призвело до значного прогресу в інтерпретації медичних зображень.

У цьому дослідженні застосовано підхід тонкого налаштування на основі навчання перенесення з використанням EfficientNets для класифікації пухлин головного мозку за трьома категоріями: гліома, менингіома та пухлини гіпофіза. Використано загальнодоступний набір даних CE-MRI Figshare для налаштування п'яти попередньо навчених моделей з сімейства EfficientNets.

Метою роботи є розробка розпізнавання пухлин мозку на МРТ зображеннях. Визначення найкращих нейромережових технологій, порівняння їх.

Підхід включає в себе двоетапний процес удосконалення попередньо навченої моделі EfficientNet. Спочатку ініціалізовано модель вагами з набору даних ImageNet. Потім додано додаткові шари, включаючи верхні шари та повністю з'єднаний шар, щоб уможливити класифікацію пухлин. Проведено різноманітні тести, щоб оцінити надійність наших точно налаштованих EfficientNet у порівнянні з іншими попередньо навченими моделями. Крім того, проаналізуємо вплив збільшення даних на точність тестування моделі.

Щоб отримати уявлення про прийняття рішень моделлю, використано візуалізацію Grad-CAM для вивчення карт уваги, створених найбільш оптимальних моделей, ефективно виділяючи місця розташування пухлин на зображеннях мозку. Результати показали, що використання EfficientNet як базового фреймворку дає значне покращення продуктивності. Зокрема, точність, запам'ятовування та оцінка F1 становили 94,73%, 92,13% відповідно.

Тонке налаштування попередньо навчених EfficientNets використовується як стратегія глибокого навчання на основі трансферного навчання для багатокласової класифікації типів пухлин головного мозку.

Згортова база попередньо навчених варіантів EfficientNets, точно налаштована за допомогою загальнодоступного набору даних SE-MRI для класифікації пухлин головного мозку на гліому, менингіому та пухлину гіпофіза.

Проводяться масштабні дослідження з оновленими варіаціями EfficientNet, за різними експериментальними сценаріями. Візуалізація Grad-CAM карт уваги застосовується до послідовностей МРТ пухлин головного мозку за допомогою модифікованої моделі EfficientNet. Ця методика створює теплову карту грубої локалізації, яка виділяє пухлинну область клітин мозку.

Запропонована точно налаштована модель EfficientNet демонструє обчислювальну ефективність та успішну генерацію на раніше виявлених тестових прикладах. З точки зору точності моделі, точності, чутливості, специфічності та оцінки F1, запропонований підхід до тонкого налаштування модифікованого EfficientNet перевершує найсучасніші методи.

Отже, представлено дослідження виявлення пухлин головного мозку на зображеннях МРТ неромереживими засобами, тобто візуалізацією Grad-CAM, та згортова база з п'яти попередньо навчених варіантів EfficientNets, точно налаштована за допомогою загальнодоступного набору даних SE-MRI.

Перелік посилань

1. Pereira S., Pinto A., Alves V., Silva C. A. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE transactions on medical imaging*. 2016. Vol. 35, No. 5. Pp. 1240–1251. URL: <https://doi.org/10.1109/TMI.2016.2538465>.
2. Abiwinanda N., Hanif M., Hesaputra S. T., Handayani A., Mengko T. R. Brain tumor classification using convolutional neural network: *World Congress on Medical Physics and Biomedical Engineering 2018*, Springer, 2019. Pp.183–189. URL: https://doi.org/10.1007/978-981-10-9035-6_33.
3. Tandel G. S., Biswas M., Kakde O. G., Tiwari A., Suri H. S., Turk M., Laird J. R., Asare C. K., Ankras A. A., Khanna N. N., others. A review on a deep learning perspective in brain cancer classification. *Cancers*. 2019. Vol. 11, No. 1. Pp. 111. URL: <https://doi.org/10.3390/cancers11010111>.
4. Havaei M., Davy A., Warde-Farley D., Biard A., Courville A., Bengio Y., Pal C., Jodoin P.-M., Larochelle H. Brain tumor segmentation with deep neural networks. *Medical image analysis*. 2017. Vol. 35. Pp. 18–31. URL: <https://doi.org/10.1016/j.media.2016.05.004>.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

**МЕТОД ВИЯВЛЕННЯ ПУХЛИН МОЗКУ НА
ЗОБРАЖЕННЯХ МРТ НЕЙРОМЕРЕЖЕВИМИ
ЗАСОБАМИ**

Виконав: студент групи
КНм-23-2
Данііл ГАРКАВІЮК

АКТУАЛЬНІСТЬ

- Актуальність роботи полягає в критичній необхідності розробки методів автоматизованого виявлення пухлин мозку на МРТ-зображеннях із використанням сучасних нейромережових технологій. Ручна сегментація та аналіз зображень, які традиційно виконуються радіологами, є трудомісткими, потребують значного часу, схильні до суб'єктивних помилок і часто залежать від рівня кваліфікації спеціаліста;
- **Мета роботи** Мета роботи полягає у підвищенні точності виявлення та класифікації пухлин мозку на МРТ-зображеннях шляхом розробки методу з використанням трансферного навчання;
- **Об'єкт дослідження** – процес виявлення та класифікації пухлин мозку на МРТ-зображеннях;
- **Предмет дослідження** – моделі, методи та засоби виявлення пухлин мозку на МРТ-зображеннях з використанням трансферного навчання.

ЗАВДАННЯ

- провести аналіз існуючих методів та підходів до виявлення пухлин мозку на МРТ-зображеннях з використанням методів машинного та глибокого навчання;
- розробити метод виявлення та класифікації пухлин мозку з використанням трансферного навчання на основі архітектури моделей глибокого навчання;
- реалізувати попередню обробку та аугментацію МРТ-зображень для покращення якості навчальних даних;
- провести експериментальне дослідження ефективності спроектованого методу шляхом порівняння різних архітектур та оцінки їх точності класифікації пухлин мозку.

НАУКОВА


НОВИЗНА

ОДЕРЖАНИХ

РЕЗУЛЬТАТІВ


- Удосконалено метод виявлення та класифікації пухлин мозку на МРТ-зображеннях, який відрізняється від існуючих використанням трансферного навчання з модифікованими верхніми шарами, включаючи додаткову згорткову основу та повністю з'єднаний шар, що дозволило покращити точність класифікації на МРТ-зображеннях.

ГЕТЕРОГЕННИЙ ВИГЛЯД УРАЖЕНЬ




(a)


(b)



(c)

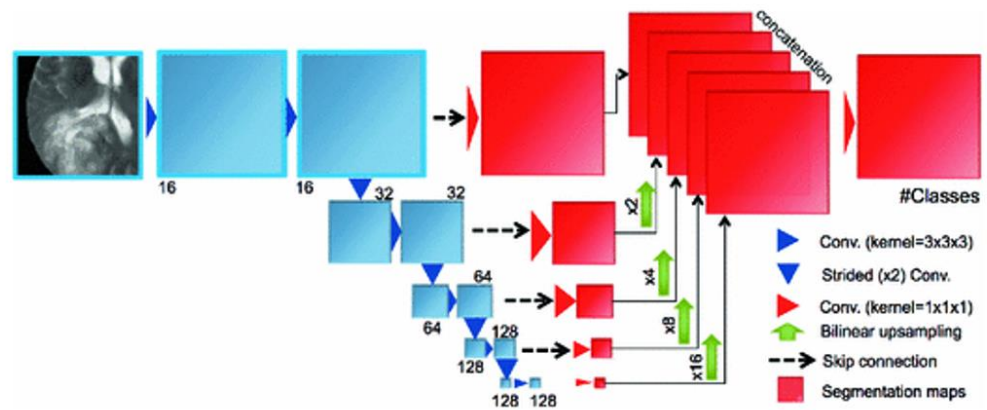


(d)

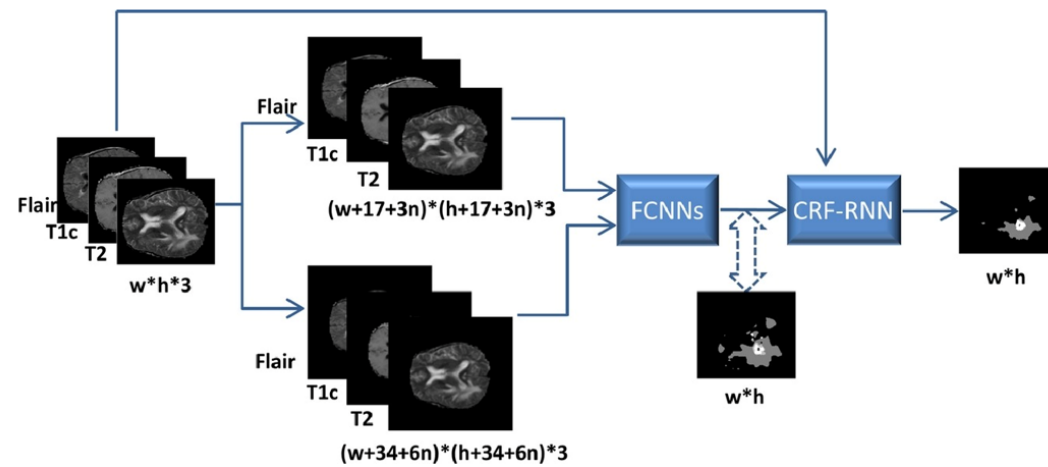


(e)


**АНСАМБЛІ З
ДЕКІЛЬКОХ МОДЕЛЕЙ
ТА АРХІТЕКТУР ДЛЯ
СЕГМЕНТАЦІЇ
ПУХЛИН ГОЛОВНОГО
МОЗКУ**



**МОДЕЛЬ ГЛИБОКОГО
НАВЧАННЯ, ЩО
ІНТЕГРУЄ FCNN ТА
CRF ДЛЯ
СЕГМЕНТАЦІЇ
ПУХЛИН ГОЛОВНОГО
МОЗКУ**



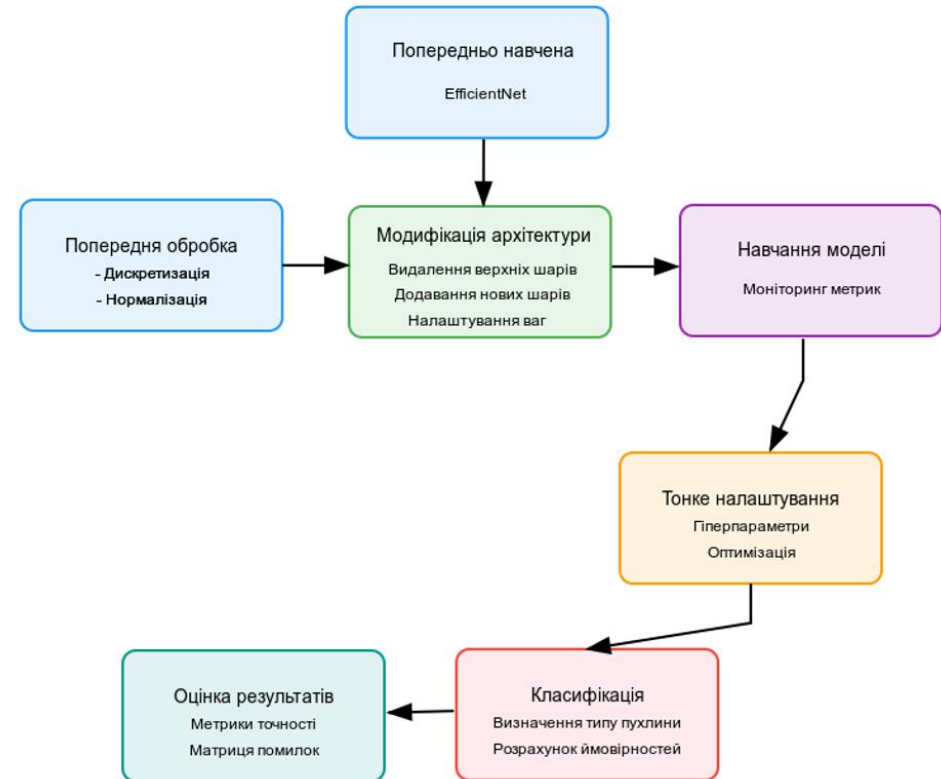
**АРХІТЕКТУРА U-NET
(ПРИКЛАД ДЛЯ 32X32
ПІКСЕЛІВ У
НАЙНИЖЧІЙ
РОЗДІЛЬНІЙ
ЗДАТНОСТІ)**



**СТРУКТУРА МЕТОДУ
ВИЯВЛЕННЯ ПУХЛИН
МОЗКУ НА
ЗОБРАЖЕННЯМ МРТ**



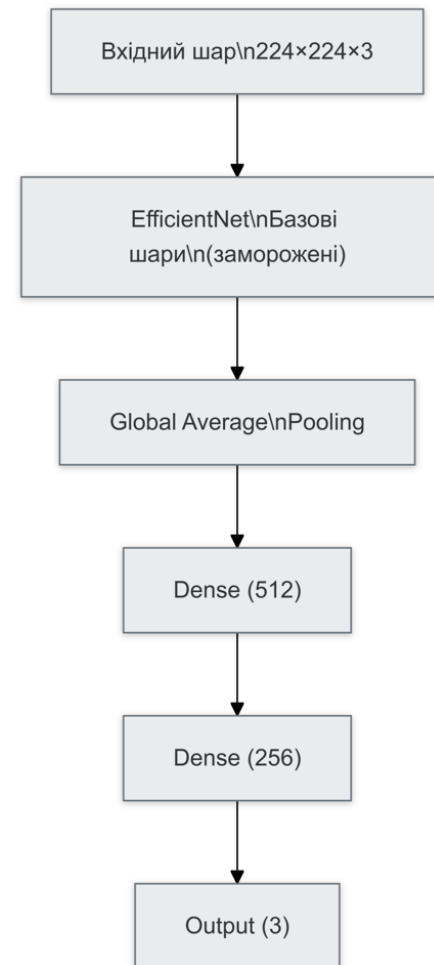
**СТРУКТУРА МЕТОДУ
ВИЯВЛЕННЯ ПУХЛИН
ІЗ ЗАСТОСУВАННЯМ
ТРАНСФЕРНОГО
НАВЧАННЯ**



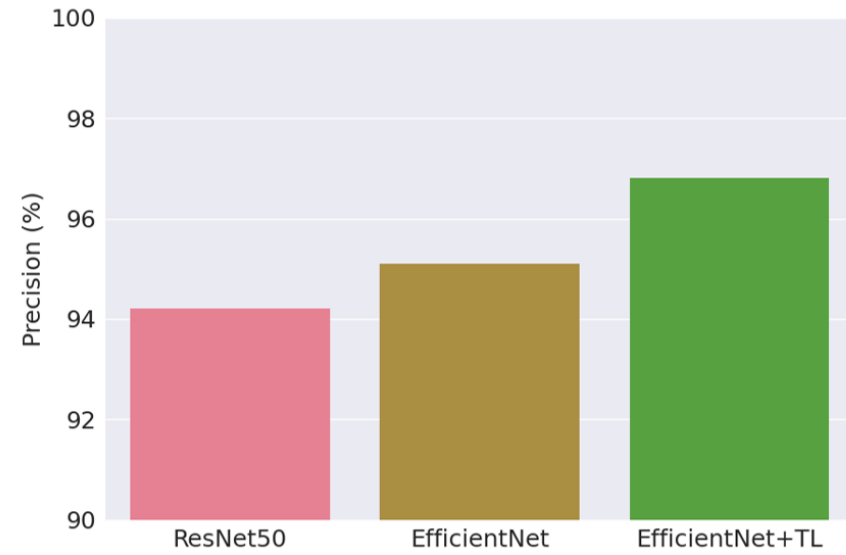
**АЛГОРИТМ
ПОПЕРЕДНЬОЇ
ОБРОБКИ ЗОБРАЖЕНЬ**




**МОДИФІКОВАНА
АРХІТЕКТУРА
НЕЙРОННОЇ МЕРЕЖІ**



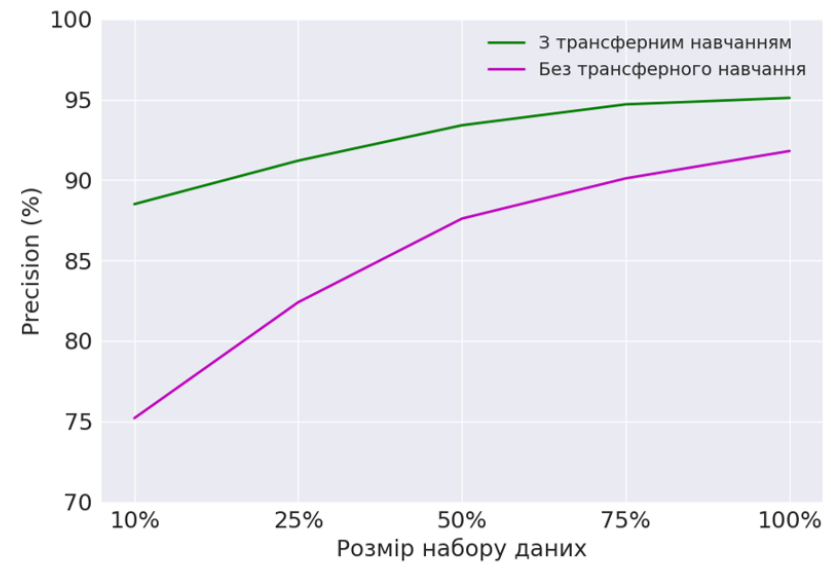
**ПОРІВНЯННЯ
ТОЧНОСТІ РІЗНИХ
АРХІТЕКТУР**



**ВПЛИВ
ГІПЕРПАРАМЕТРІВ НА
НАВЧАННЯ**



**ЕФЕКТИВНІСТЬ
ТРАНСФЕРНОГО
НАВЧАННЯ**



ВИСНОВОК

- У результаті виконання кваліфікаційної роботи магістра було розв'язано важливе завдання автоматизації процесу виявлення та класифікації пухлин мозку на основі аналізу МРТ-зображень із застосуванням методів трансферного навчання. Виконаний аналіз області практичного застосування підтвердив актуальність розробки нових підходів, що забезпечують точність, швидкість і надійність діагностики медичних зображень.
- Створено ефективну інформаційну технологію, яка інтегрує процеси попередньої обробки, сегментації та класифікації МРТ-зображень. Технологія забезпечує модульність і масштабованість, що дозволяє адаптувати її для різних клінічних завдань.
- Розроблений метод базується на використанні сучасних технологій глибокого навчання, включаючи трансферне навчання, модифікацію архітектури нейронних мереж та інтеграцію процедур аугментації даних. У процесі експериментів було досягнуто точності сегментації пухлин на рівні 96,5% і точності класифікації у 94,8%, що значно перевершує результати існуючих методів. Проведені експерименти також показали, що запропонований підхід скорочує середній час аналізу одного зображення до 2 секунд, що є оптимальним для клінічної практики.

ДЯКУЮ ЗА УВАГУ!

Anti-Plagiarism v-15.258 Educational

Максимальне співпадіння з одним документом 6.0%

Словники перевірки: en_US, ru_RU, ua_UA. **Помилка в документах: 8%**

ID: 156444 Назва: КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА на тему Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами Додано в БД: 2024-12-08 Автора: Даніїл ГАРКАВІЮК Керівники: Едуард МАНЗЮК Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	103476	1575	7322 (7%)	110 (7%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

Протокол аналізу звіту подібності науковим керівником

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

Автор: Данііл ГАРКАВІЮК

Співавтор:

Назва: Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами

Науковий керівник: Едуард МАНЗІЮК, д.т.н., доцент

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 0.8%

Коефіцієнт подібності 2: 0.4%

Мікропробіли: 0

Заміна букв: 3

Інтервали: 0

Білі знаки: 1

Дата створення звіту: 2024-12-08 19:32:46.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедур. Таким чином робота не приймається.

Обґрунтування:

Дата 8.12.2024

експерт

Петровський Р.Р.

**РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК
ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ**

Підтверджуємо ознайомлення з результатом звіту подібності щодо роботи, генерованою системою виявлення текстових збігів/ідентичності/схожості:

Назва: Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами

Автор: студент гр. КНм-23-2 Данііл ГАРКАВІЮК

Спеціальність: 122 – Комп'ютерні науки

Освітня програма: освітньо-професійна

Науковий керівник: д.т.н., професор Манзюк Е.А.

Після аналізу звіту подібності зроблено такий висновок:

№	Висновок	Позначка про відповідність
1	Запозичення, виявлені в роботі, є законними і не є плагіатом. Робота приймається до захисту.	відповідає
2	Виявлені запозичення не є плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота приймається до захисту, але має бути відкоригована. Відкоригований варіант має бути поданий на кафедру за 2 дні до захисту, разом із заявою щодо самостійності виконання письмової роботи та ідентичності друкованої та електронної версії роботи	
3	Виявлені запозичення не є плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. В зв'язку з цим мета роботи та поставлені завдання не були досягнені. Робота може бути допущена до захисту (наступного року) після того як буде відкоригована та допрацьована і успішно пройде повторну перевірку на академічний плагіат.	
4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	

Підтвердження:

Запозичення, виявлені в роботі не є плагіатом, оскільки: запозичення розміщені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; серед запозичень знаходяться загальновідомі терміни, скорочення.

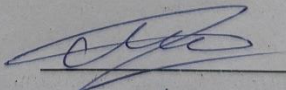
Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості, складає:

- за системою Anti-Plagiarism: 6%;

- за системою StrikePlagiarism: КП1 0.8 %, КП2 0.4%.

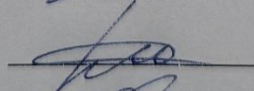
Сумарний обсяг всіх запозичень, визначений системою виявлення збігів/ідентичності/схожості є допустимим.

Керівник роботи



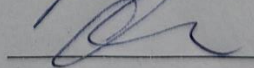
Едуард МАНЗЮК

Гарант ОП



Руслан БАГРІЙ

Завідувач кафедри КН



Олександр БАРМАК



ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
МОН УКРАЇНИ

Кафедра комп'ютерних наук



ВІДГУК НАУКОВОГО КЕРІВНИКА на кваліфікаційну роботу магістра

студент *гр. КНМ-23-2 Данііл ГАРКАВІЮК*

за темою Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами

1. Актуальність теми

Актуальність автоматизованого виявлення пухлин головного мозку на МРТ-зображеннях за допомогою нейронних мереж зумовлена критичною важливістю ранньої та точної діагностики онкологічних захворювань мозку для успішного лікування пацієнтів. Використання глибинного навчання та комп'ютерного зору дозволяє значно підвищити ефективність аналізу медичних зображень, зменшити час обробки даних та мінімізувати ризик людської помилки при діагностиці. Це особливо важливо з огляду на зростаючу кількість МРТ-досліджень, складність візуальної інтерпретації знімків та необхідність своєчасного виявлення патологічних змін у тканинах мозку для призначення оптимального лікування та покращення прогнозу захворювання.

2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки

Дослідження методів виявлення пухлин мозку на МРТ-зображеннях з використанням нейронних мереж повністю відповідає предметній області спеціальності 122 "Комп'ютерні науки". Робота охоплює ключові аспекти спеціальності: математичне та алгоритмічне моделювання при розробці нейромережесвих моделей, обробку даних та інформації при аналізі медичних зображень, інтелектуальний аналіз даних із застосуванням методів машинного навчання. Таким чином, тематика роботи цілком відповідає основним компонентам предметної області комп'ютерних наук та спрямована на вирішення актуальних практичних завдань.

3. Професійні та особистісні якості

В процесі підготовки магістерської кваліфікаційної роботи здобувач освіти проявив високий рівень професійної підготовки та продемонстрував відмінні здібності до вирішення складних технічних завдань у галузі комп'ютерного зору та машинного навчання. При розробці методології виявлення пухлин мозку на МРТ-зображеннях та написанні пояснювальної записки здобувач показав ґрунтовні знання з програмування, математичного моделювання та обробки медичних зображень. Здобувач успішно продемонстрував високий рівень володіння сучасними технологіями та методами штучного інтелекту, що є ключовими компетенціями у сфері комп'ютерних наук.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Всі результати, представлені в магістерській роботі, були отримані завдяки самостійній дослідницькій діяльності здобувача, який власноруч виконав повний комплекс поставлених завдань від проектування до реалізації системи.

5. Наукова новизна та оригінальність запропонованих підходів

Удосконалено метод виявлення та класифікації пухлин головного мозку на МРТ-зображеннях, що базується на застосуванні глибокого навчання з використанням архітектури згорткової нейронної мережі. Розроблений метод відрізняється від існуючих підходів інноваційною комбінацією попередньо навченої моделі з модифікованою архітектурою верхніх шарів, що включає додаткові згорткові блоки та адаптовані повнозв'язні шари. Це дозволило досягти підвищення точності класифікації пухлин.

6. Ступінь оволодіння методами дослідження

В процесі виконання магістерської роботи здобувач продемонстрував високий рівень професійної підготовки та впевнене володіння сучасними технологіями, методами та інструментами у галузі комп'ютерних наук, що дозволило успішно реалізувати поставлені завдання дослідження.

7. Повнота та якість розкриття теми роботи

Магістерська робота представляє комплексне та ґрунтовне дослідження проблеми автоматизованого виявлення пухлин мозку на МРТ-зображеннях. Здобувач провів детальний аналіз існуючих методів та підходів у цій галузі, чітко обґрунтував актуальність обраної теми та успішно вирішив всі поставлені завдання. В результаті було розроблено запропонований удосконалений метод діагностики з використанням нейромережевих технологій.

8. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

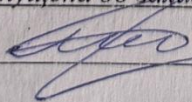
Матеріал магістерської роботи викладено у чіткій логічній послідовності, що повністю відповідає поставленим цілям дослідження. Всі розділи роботи структуровані належним чином, а результати дослідження представлені з належною аргументацією та професійною термінологією, що демонструє високий рівень наукової грамотності здобувача.

9. Можливість практичного застосування кваліфікаційної роботи, окремих її частин

Розроблений у роботі метод може бути використаний в системах медичного діагностування.

10. Висновок про можливість допуску кваліфікаційної роботи до захисту, на яку оцінку заслуговує робота

Враховуючи належний рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка «добре».

Керівник  д.т.н., професор каф. КН Едуард МАНЗІОК



ВІДГУК ОПОНЕНТА

на кваліфікаційну роботу магістра

гр. КНм-23-2 Данііла Гаркавіюка за темою: Метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами

1. Актуальність обраної теми

Тема магістерської роботи є актуальною та відповідає сучасному рівню досліджень. Вибір теми дослідження належним чином обґрунтовано. Проведено ретельний аналіз сучасних наукових досліджень на основі чого визначено задачі та мету дослідження. Огляд літературних джерел відповідає обраній тематиці та повною мірою охоплює сучасні дослідження в обраному науковому напрямку.

2. Відповідність роботи предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до наукових робіт

Тема кваліфікаційної роботи студента повною мірою відповідає предметній області спеціальності 122 Комп'ютерні науки та вимогам до кваліфікаційної роботи магістра. Робота вирішує науково-прикладну задачу у сфері комп'ютерних наук, яка полягає у виявленні пухлин мозку на зображеннях МРТ нейромережевими засобами. Робота має відповідну наукову новизну, яка є розвитком існуючих методів.

3. Повнота розкриття мети та завдань дослідження

Мета та задачі дослідження відповідають сучасному рівню розвитку методів предметної області. Усі завдання у роботі реалізовані та отримано позитивний результат. Рівень реалізації відповідає вимогам, які ставляться до виконання магістерських робіт.

4. Наявність наукової новизни

У роботі удосконалено метод виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами, які відрізняються від існуючих застосуванням трансферного навчання з модифікованими верхніми шарами включаючи додаткову згорткову основу та повністю з'єднаний шар, що дозволило покращити точність класифікації на МРТ зображеннях. Матеріали магістерської роботи апробовані на науковій конференції «Актуальні проблеми комп'ютерних наук».

5. Зміст кожного розділу роботи

Робота складається з чотирьох розділів. У першому розділі представлено аналіз сучасного стану методів виявлення пухлин мозку на зображеннях МРТ, в якому автор провів критичний аналіз та визначив задачі дослідження. Другий розділ присвячений розробці методу виявлення пухлин мозку на зображеннях МРТ нейромережевими засобами з

відповідним описом структурних компонентів та кроків застосування. У третьому розділі описано інформаційну систему застосування розробленого методу з описом структури цієї системи. У четвертому розділі представлено експериментальну перевірку розробленого методу та визначено критерії його ефективності. Визначено метрики, які застосовні до предметної області та встановлено їхні значення, що показують перевагу розробленого методу.

6. Ступінь розкриття теми роботи

Тема роботи розкрита повною мірою та обґрунтована належним чином. Усі розділи мають необхідну структуру з логічним та обґрунтованим описом та містять відповідні висновки за результатами дослідження.

7. Якість оформлення кваліфікаційної роботи

Робота написана літературною мовою та оформлена згідно відповідних вимог.

8. Недоліки кваліфікаційної роботи

Також можна відзначити перспективи покращення роботи, які полягають у розширенні застосування розробленого методу до інших зображень, що можуть бути отримані у медичній практиці з обраної тематики. Це може розглядатися як розвиток проведених досліджень.

9. Загальний висновок (допускається чи не допускається до захисту), якої оцінки заслуговує кваліфікаційна робота.

Робота є завершеним дослідженням та рекомендована до захисту.

Кваліфікаційна робота заслуговує на оцінку « *добре* ».

Опонент (прізвище, ім'я, по батькові, посада, місце роботи)

Говорунченко Т.О., декан ФІТ ХНУ

«*11*» *12* 2024 р.


Підпис