

ДЕРЖАВНИЙ УНІВЕРСИТЕТ ІНФОРМАЦІЙНО-
КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ
НАВЧАЛЬНО-НАУКОВИЙ ІНСТИТУТ ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ КАФЕДРА ІНЖЕНЕРІЇ ПРОГРАМНОГО
ЗАБЕЗПЕЧЕННЯ АВТОМАТИЗОВАНИХ СИСТЕМ

КВАЛІФІКАЦІЙНА РОБОТА

на тему:

«Дослідження використання нейромереж у медицині»

на здобуття освітнього ступеня бакалавра

зі спеціальності 126 Інформаційні системи та технології

(код, найменування спеціальності)

освітньо-професійної програми Інформаційні системи та технології

(назва)

*Кваліфікаційна робота містить результати власних досліджень.
Використання ідей, результатів і текстів інших авторів мають посилання на
відповідне джерело*

(підпис)

Богдан ПЕТЛИЦЬКИЙ
Ім'я, ПРІЗВИЩЕ здобувача

Виконав: здобувач вищої освіти гр. ІСД- 41

Богдан ПЕТЛИЦЬКИЙ

Ім'я, ПРІЗВИЩЕ

Керівник: PhD Валентина ДАНИЛЬЧЕНКО

науковий ступінь,
вчене звання

Ім'я, ПРІЗВИЩЕ

Рецензент:

науковий ступінь,
вчене звання

Ім'я, ПРІЗВИЩЕ

Київ 2024

ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ

Навчально-науковий інститут Інформаційних технологій

Кафедра Інженерії програмного забезпечення автоматизованих систем
Ступінь вищої освіти бакалавр
Спеціальність Інформаційні системи та технології
Освітньо-професійна програма Інформаційні системи та технології

ЗАТВЕРДЖУЮ

Завідувач кафедру ІІЗАС
_____ Каміла СТОРЧАК
«_____» _____ 2024 р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

Петлицькому Богдану Романовичу
(прізвище, ім'я, по батькові здобувача)

1. Тема кваліфікаційної роботи: Дослідження використання нейромереж у медицині

керівник кваліфікаційної роботи Валентина ДАНИЛЬЧЕНКО PhD
(Ім'я, ПРІЗВИЩЕ, науковий ступінь, вчене звання)

Затверджені наказом Державного університету інформаційно-комунікаційних технологій від «27» лютого 2024 р. № 36

2. Строк подання кваліфікаційної роботи «31» травня 2024 р.

3. Вихідні дані до кваліфікаційної роботи:

1. Науково-технічна література з теми бакалаврської роботи.
2. Принципи дослідження медичних знімків за допомогою нейромережі.
3. Застосування різних методів для класифікації зображень та тренування нейронних мереж з використанням різних моделей.

4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити)

1. Аналіз існуючих технологій штучного інтелекту для аналізу медичних знімків.
2. Виявлення перспектив та обмежень впровадження існуючих методів для підвищення результативності у виявленні раку на знімках.

5. Ілюстративний матеріал: *презентація*

6. Дата видачі завдання: «27» лютого 2024 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1	Аналіз наявної науково-технічної літератури	27.02-05.03.2024	
2	Обґрунтування актуальності роботи	06.03-11.03.2024	
3	Аналіз основних принципів впровадження штучного інтелекту в систему охорони здоров'я	12.03-05.04.2024	
4	Аналіз існуючі методів використання нейромереж у медицині	06.04-15.04.2024	
5	Розробка алгоритму заснованому на послідовному процесі, що полягає у виявленні аномалій на медичних зображеннях	16.04-15.05.2024	
7	Оформлення роботи: вступ, висновки, реферат	16.05-22.05.2024	
8	Розробка демонстраційних матеріалів	23.05-24.05.2024	

Здобувач вищої освіти

(підпис)

Богдан ПЕТЛИЦЬКИЙ

(Ім'я, ПРІЗВИЩЕ)

Керівник
кваліфікаційної роботи

(підпис)

Валентина ДАНИЛЬЧЕНКО

(Ім'я, ПРІЗВИЩЕ)

РЕФЕРАТ

Текстова частина кваліфікаційної роботи на здобуття освітнього ступеня бакалавра: 50 стор., 1 табл., 32 рис., 21 джерел.

Мета роботи – вивчення теоретичних основ нейронних мереж та їх застосування у медицині.

Об'єкт дослідження – нейронні мережі як інструмент для діагностики раку грудей.

Предмет дослідження – нейронні мережі як інструмент для діагностики раку грудей.

Короткий зміст роботи: Дипломна робота присвячена вивченню можливостей застосування нейронних мереж у медичній діагностиці, зокрема для виявлення та аналізу раку грудей. У роботі розглянуто сучасні методології обробки та класифікації медичних зображень із використанням нейронних мереж, а також проаналізовано їх ефективність.

Результати дослідження демонструють, що методологія GLCM перевершує інші підходи за такими критеріями, як точність, чутливість та специфічність. GLCM виявилася особливо ефективною у виділенні текстурних особливостей зображень, що є критичним для точного розпізнавання ракових утворень.

Ключові слова: НЕЙРОННІ МЕРЕЖІ, МЕДИЧНА ДІАГНОСТИКА, АНАЛІЗ МЕДИЧНИХ ЗОБРАЖЕНЬ, КЛАСИФІКАЦІЯ ЗОБРАЖЕНЬ, ШТУЧНИЙ ІНТЕЛЕКТ, СЕГМЕНТАЦІЯ ЗОБРАЖЕНЬ, МАШИННЕ НАВЧАННЯ, ГЛИБОКЕ НАВЧАННЯ, ВИЯВЛЕННЯ ПАТОЛОГІЙ

ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ
Навчально-науковий інститут _____

**ПОДАННЯ
ГОЛОВІ ЕКЗАМЕНАЦІЙНОЇ КОМІСІЇ
ЩОДО ЗАХИСТУ КВАЛІФІКАЦІЙНОЇ РОБОТИ**

Направляється здобувач Петлицький Б.Р. до захисту кваліфікаційної роботи
(прізвище та ініціали)

за спеціальністю **126 Інформаційні системи та технології**
(код, найменування спеціальності)

освітньо-професійної програми _____
(назва)

на тему: «Дослідження використання нейромереж у медицині».

Кваліфікаційна робота і рецензія додаються.

Директор ННІТ _____
(підпис) (Ім'я, ПРІЗВИЩЕ)

Висновок керівника кваліфікаційної роботи

Здобувач _____

Все це дозволяє оцінити виконану кваліфікаційну роботу здобувача _____ на оцінку « _____ » та присвоїти йому (їй) кваліфікацію _____.

Керівник кваліфікаційної роботи _____
(підпис) (Ім'я, ПРІЗВИЩЕ)

“ _____ ” _____ 20__ року

Висновок кафедри про кваліфікаційну роботу

Кваліфікаційна робота розглянута. Здобувач *Петлицький Б.Р.* допускається до захисту даної роботи в Екзаменаційній комісії.

Завідувач кафедрою _____
(назва) (підпис) (Ім'я, ПРІЗВИЩЕ)

ВІДГУК РЕЦЕНЗЕНТА
на кваліфікаційну роботу
на здобуття освітнього ступеня бакалавра

здобувача(ки) вищої освіти _____ Петлицький Богдан Романович

(прізвище, ім'я, по батькові)

на тему: «Дослідження використання нейромереж у медицині»

Актуальність.

Кваліфікаційна робота Петлицького Богдана Романовича на тему «Дослідження використання нейромереж у медицині» є надзвичайно актуальною, оскільки сучасна медицина все більше покладається на новітні технології для покращення діагностики та лікування захворювань. Використання нейронних мереж для аналізу медичних зображень є перспективним напрямком, який дозволяє підвищити точність діагностики, зменшити час обробки даних та знизити людський фактор у медичних помилках. Зокрема, дослідження раку грудей є критично важливим, оскільки це захворювання є однією з провідних причин смертності серед жінок у всьому світі. Отже, робота має не лише наукову, але й велику соціальну значущість.

Позитивні сторони.

1. **Глибоке дослідження:** Робота демонструє глибоке розуміння теоретичних аспектів нейронних мереж та їх застосування в медицині. Здобувач детально розглядає різні методології та порівнює їх ефективність.
2. **Інноваційність:** Використання GLCM для текстурного аналізу медичних зображень є інноваційним підходом, який забезпечує високу чутливість до локальних варіацій у тканинах, що є важливим для виявлення патологій

Недоліки.

1. **Обмеженість даних:** Робота може бути обмежена в частині доступних даних для навчання нейронних мереж. В майбутньому варто розглянути можливість використання більших та більш різноманітних наборів даних для підвищення загальної узагальненості моделі.
2. **Оцінка ефективності:** Було б корисно включити порівняння результатів з іншими сучасними методами аналізу медичних зображень, щоб ще більш детально продемонструвати переваги та можливі недоліки обраного підходу.

Відзначені зауваження не впливають на загальну позитивну оцінку кваліфікаційної роботи бакалаврської.

Висновок: *кваліфікаційна робота на здобуття ступеня бакалавра заслуговує оцінку*

«відмінно», а здобувач(ка) Петлицький Б.Р. заслуговує присвоєння кваліфікації: бакалавр

Рецензент:

науковий ступінь, вчене звання

підпис

Ім'я, ПРІЗВИЩЕ

ВСТУП.....	8
РОЗДІЛ 1 Дослідження раку грудей, та загальна характеристика нейронних мереж.....	12
1.1 Нейронні мережі у медицині.....	15
1.2 Машинне навчання, та загальна характеристика нейронних мереж.....	16
РОЗДІЛ 2 Дослідження існуючих методів розпізнавання медичних зображень	21
2.1 Згорткові нейронні мережі	23
2.2 Класифікатори, засновані на обробці простору характеристик	28
2.2.1 Логістична регресія	28
2.2.2 Метод k-ближчих сусідів (k-NN)	30
2.2.3 Метод опорних векторів (SVM)	34
2.2.4 HD-CNN	35
РОЗДІЛ 3 Практична реалізація.....	37
3.1 Алгоритми класифікації даних.....	38
3.2 Штучні нейронні мережі	38
3.3 Оцінка якості класифікації	43
3.4 Проведення експериментів	48
3.5 Покращення зображення	50
3.6 Результати	51
3.7 Експериментальна реалізація.....	55
ВИСНОВКИ.....	56
ПЕРЕЛІК ПОСИЛАНЬ.....	57
ДЕМОНСТРАЦІЙНІ МАТЕРІАЛИ (Презентація)	82

ВСТУП

Сучасна медицина стрімко розвивається, постійно впроваджуючи нові технології та методи для покращення діагностики, лікування та профілактики захворювань. Одним з перспективних напрямків досліджень є використання штучного інтелекту, зокрема нейронних мереж, у цій сфері.

Нейронні мережі – це математичні моделі, що імітують роботу людського мозку. Вони здатні навчатися на великих обсягах даних, виявляти складні закономірності та робити прогнози. Ці властивості роблять їх потужним інструментом для вирішення різноманітних медичних задач.

Актуальність дослідження використання нейронних мереж у медицині обумовлюється:

Зростанням обсягів медичних даних: Завдяки розвитку діагностичних методів та електронних медичних записів кількість даних про пацієнтів постійно зростає. Аналіз цих даних за допомогою традиційних методів може бути складним та трудомістким, а нейронні мережі здатні впоратися з цим завданням значно швидше та ефективніше.

Складністю медичних задач: Багато медичних задач, таких як діагностика захворювань, прогнозування результатів лікування та розробка нових ліків, є складними та багатofакторними. Нейронні мережі здатні враховувати множину факторів та робити точніші прогнози, ніж традиційні методи.

Потенціалом для покращення охорони здоров'я: Використання нейронних мереж у медицині може призвести до покращення діагностики, лікування та профілактики захворювань, а також до зниження витрат на охорону здоров'я.

Актуальність дослідження використання нейронних мереж у медицині підкреслюється низкою факторів:

Зростаючим інтересом наукової спільноти: За останні роки кількість публікацій, присвячених цій темі, значно зросла. Це свідчить про те, що дослідження в цій сфері є активними та перспективними.

Підтримкою з боку держави та приватного сектору: Уряди багатьох країн та приватні компанії інвестують значні кошти в дослідження та розробки штучного інтелекту, зокрема й у його медичні застосування.

Позитивними результатами перших досліджень: Ряд досліджень вже продемонстрував, що нейронні мережі можуть бути ефективно використані для вирішення різних медичних задач.

Метою дослідження є вивчення теоретичних основ нейронних мереж та їх застосування у медицині, аналіз сучасного стану досліджень у цій сфері, дослід методів використання нейронної мережі для вирішення конкретних медичних задач, оцінити ефективність запропонованого методу та сформулювати висновки щодо його перспективності.

Для досягнення поставленої мети необхідно вирішити наступні завдання:

- Ознайомитися з теоретичними основами нейронних мереж та їх типами.
- Вивчити методи навчання та тренування нейронних мереж.
- Проаналізувати існуючі методи використання нейронних мереж у медицині.
- Вибрати конкретну медичну задачу для дослідження.
- Розробити архітектуру нейронної мережі для вирішення цієї задачі.
- Зібрати та підготувати дані для навчання та тестування нейронної мережі.
- Навчити та протестувати нейронну мережу.
- Оцінити ефективність запропонованого методу.

- Сформулювати висновки щодо перспективності використання нейронних мереж для вирішення обраної медичної задачі.

Об'єктом дослідження є нейронні мережі як інструмент для діагностики раку грудей. Це означає, що ми будемо вивчати можливості нейронних мереж в автоматизації та покращенні процесу діагностики цієї поширеної та небезпечної хвороби.

Предметом дослідження є методи та алгоритми використання нейронних мереж для аналізу медичних зображень з метою діагностики раку грудей. Це означає, що ми будемо зосереджуватися на тому, як саме нейронні мережі можуть бути застосовані для інтерпретації мамограм, виявлення пухлин та інших ознак раку на зображеннях.

Для досягнення поставленої мети та вирішення задач дослідження будуть використовуватися наступні методи:

Аналіз літератури: Вивчення наукових публікацій, присвячених нейронним мережам та їх медичним застосуванням.

Метод моделювання: Розробка та реалізація математичної моделі нейронної мережі для вирішення конкретної медичної задачі.

Експериментальне дослідження: Навчання та тестування нейронної мережі на наборі даних про пацієнтів.

Статистичний аналіз: Оцінка ефективності запропонованого методу з допомогою статистичних методів.

1 ДОСЛІДЖЕННЯ РАКУ ГРУДЕЙ, ТА ЗАГАЛЬНА ХАРАКТЕРИСТИКА НЕЙРОННИХ МЕРЕЖ

Рак грудей - найпоширеніший рак серед жінок у світі. За даними Всесвітньої організації охорони здоров'я (ВООЗ), у 2020 році було зареєстровано 2,3 мільйона нових випадків раку грудей, що становить 25% всіх випадків раку у жінок.

В Україні, за даними Національного інституту раку, щороку діагностується близько 17 000 випадків раку грудей. Цей тип раку є також однією з найпоширеніших причин смерті серед жінок, щороку забираючи життя близько 7 000 українок.

Існує два основних типи раку грудей: інвазивний і неінвазивний

Неінвазивний рак грудей не поширився за межі молочних проток або часточок. Він також називається раком «in situ». Існує два основних типи неінвазивного раку грудей:

- Протокова карцинома in situ (DCIS): Це найпоширеніший тип неінвазивного раку грудей. Він починається в протоках, які є каналами, що транспортують молоко з сосків.(Рис 1.1)

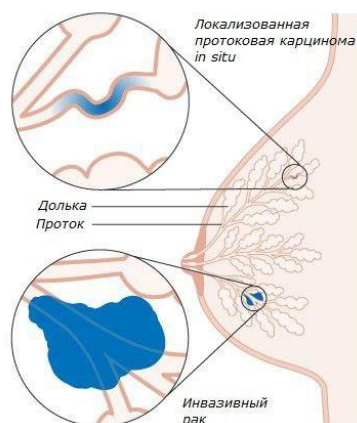


Рис 1.1 - Протокова карцинома in situ (DCIS)

- Лобулярна карцинома in situ (LCIS): Цей тип раку починається в часточках, які є залозистими структурами, що виробляють молоко.(Рис 1.2)




Рис 1.2 - Лобулярна карцинома in situ (LCIS)

Інвазивний рак грудей поширився за межі молочних проток або часточок у навколишні тканини грудей. Існує кілька типів інвазивного раку грудей, включаючи:

- Інвазивна протокова карцинома: Цей тип раку є найпоширенішим типом інвазивного раку грудей. Він починається в протоках і поширюється на навколишні тканини.(Рис 1.3)

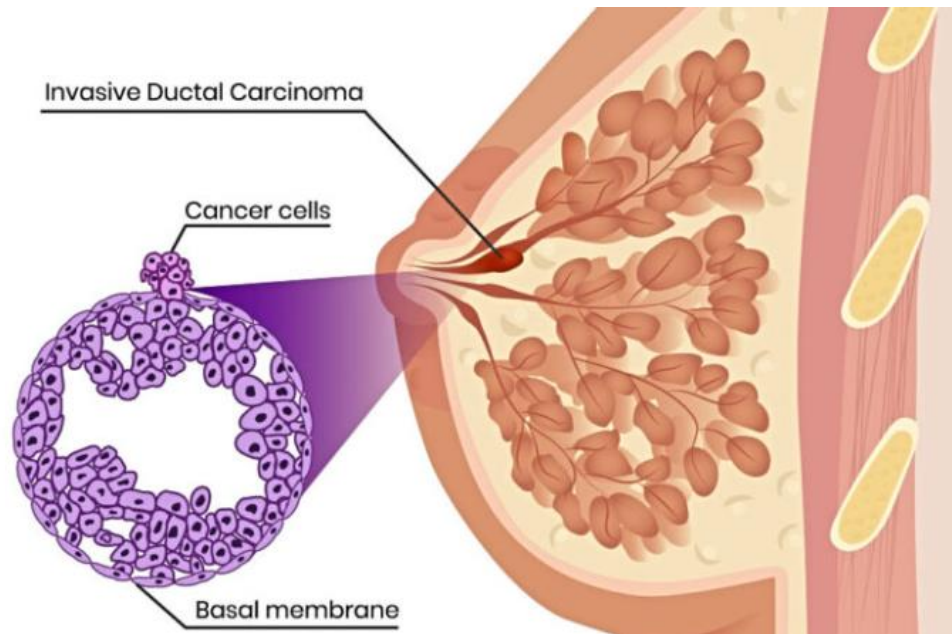


Рис 1.3 - Інвазивна протокова карцинома

- Інвазивна лобулярна карцинома: Цей тип раку починається в часточках і поширюється на навколишні тканини.(Рис 1.4)

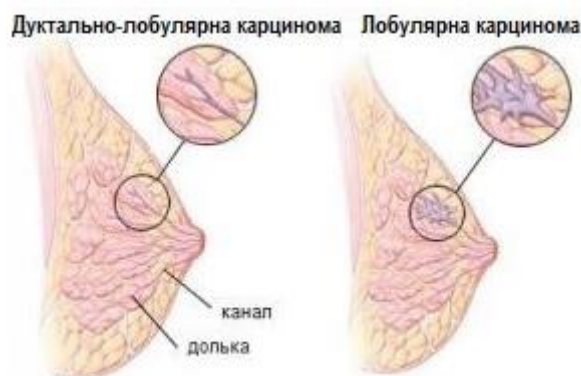


Рис 1.4 - Інвазивна лобулярна карцинома

- Запальний рак грудей: Цей тип раку рідкісний, але агресивний. Він викликає почервоніння, набряк і потовщення шкіри грудей.

1.1 Нейронні мережі у медицині

Нейронні мережі (НМ) створюють революцію в медицині, пропонуючи інноваційні рішення для діагностики, лікування та досліджень. Їхня здатність

навчатися на великих обсягах даних та виявляти складні закономірності робить їх потужним інструментом для покращення охорони здоров'я.

Ось деякі з ключових напрямків застосування нейронних мереж у медицині:

1. Діагностика:

- Аналіз медичних зображень: НМ можуть аналізувати рентгенівські знімки, МРТ, КТ та інші медичні зображення, щоб виявляти патології з високою точністю. Це може допомогти лікарям ставити діагнози швидше, точніше та з меншою кількістю помилок.
- Персоналізована медицина: НМ можна використовувати для аналізу даних про пацієнта, таких як його геном, медична історія та спосіб життя, щоб передбачати ризик розвитку захворювань та рекомендувати персоналізовані плани лікування.
- Підтримка прийняття рішень лікарями: НМ можуть надавати лікарям інформацію та рекомендації під час діагностики та лікування пацієнтів, допомагаючи їм приймати кращі рішення.

2. Лікування:

- Розробка ліків: НМ можна використовувати для ідентифікації нових мішеней для ліків та розробки нових та більш ефективних методів лікування.
- Роботизована хірургія: НМ можуть керувати роботизованими хірургічними системами, забезпечуючи більшу точність та мінімізуючи інвазивність операцій.
- Персоналізована терапія: НМ можна використовувати для розробки персоналізованих планів лікування для кожного пацієнта, враховуючи його унікальні потреби та характеристики.

3. Дослідження:

- Відкриття ліків: НМ можна використовувати для аналізу великих обсягів даних про молекули, щоб ідентифікувати потенційні нові ліки та розробляти нові методи лікування.
- Розуміння захворювань: НМ можна використовувати для аналізу даних про захворювання, щоб краще зрозуміти їх причини, механізми розвитку та потенційні методи лікування.
- Розробка нових медичних технологій: НМ можна використовувати для розробки нових медичних технологій, таких як носимі пристрої та програмне забезпечення для моніторингу стану здоров'я.

Важливо зазначити, що нейронні мережі все ще перебувають на стадії розробки для медичних застосувань. Існують певні проблеми, такі як упередженість, прозорість та інтерпретабельність, які потрібно вирішити, перш ніж вони зможуть бути широко впроваджені в клінічній практиці.

Однак потенціал нейронних мереж для покращення охорони здоров'я є величезним. Завдяки постійним дослідженням та розробкам нейронні мережі, ймовірно, відіграватимуть ще більшу роль у майбутньому медицини, рятуючи життя та покращуючи якість життя людей у всьому світі.

1.2 Машинне навчання та загальна характеристика нейронних мереж

За останнє десятиліття інтерес до машинного навчання значно зріс. Зараз воно використовується в досить широкому спектрі, включаючи комп'ютерні програми, фондові біржі, інженерію та звичайно медицину. По суті, машинне навчання - це використання алгоритмів для вилучення інформації з необроблених даних, представлення її у вигляді типізованої моделі, а потім використання цієї моделі для виведення інформації про нові дані.

Артур Семюел (рис 1.5), піонер у галузі штучного інтелекту (ШІ) в ІВМ і Стенфордї, визначив машинне навчання в 1959 році як процес, за допомогою якого машина (комп'ютер) здатна демонструвати поведінку, яка не була явно запрограмована в ній. Формальне визначення машинного навчання дав Том Мітчелл (рис 1.6), американський вчений і професор Університету Карнегі-Меллона.

Кажуть, що комп'ютерна програма навчається на основі досвіду E щодо відношенню до деякого класу завдань T і міри якості P , якщо якість розв'язання задач із T , виміряна на основі P , поліпшується з набуттям досвіду E .



рис 1.5 - Артур Семюел



рис 1.6 – Том Мітчелл

Штучні нейронні мережі - це клас моделей машинного навчання, в основі яких лежать дослідження центральної нервової системи ссавців. Нейромережа складається з декількох взаємопов'язаних нейронів, організованих у шари, які

обмінюються між собою повідомленнями при виконанні певних умов. Загальну структуру нейронної мережі продемонстровано на малюнку 1.3. Елементарним перетворювачем у даних мережах є штучний нейрон або просто нейрон, названий так за аналогією з біологічним прототипом. До теперішнього часу запропоновано і вивчено велику кількість моделей нейроподібних елементів і нейронних мереж.




Рис 1.7. - Класична топологія нейромережі, із вхідним, вихідним, що приймає рішення про клас, і асоціативним шаром

Нейрон є складовою частиною нейронної мережі. Він складається з елементів трьох типів: помножувачів (синапсів), суматора та нелінійного перетворювача. Синапси здійснюють зв'язок між нейронами, множать вхідний сигнал на число, що характеризує силу зв'язку (вага синапса). Суматор виконує додавання сигналів, що надходять синаптичними зв'язками від інших нейронів, і зовнішніх вхідних сигналів. Нелінійний перетворювач реалізує нелінійну функцію одного аргументу - виходу суматора. Ця функція називається функцією активації або передавальною функцією нейрона. Загальну структуру нейрона продемонстровано на рисунку 1.8.




Рис 1.8. - Структура штучного нейрона

Нейрон загалом реалізує скалярну функцію векторного аргументу. Математична модель нейрона показана на формулі:

$$S = \sum_{i=1}^n w_i x_i + b; y = f(s)$$

Формула 1.1 - Математична модель нейрона

де - S результат суми (sum);

$w(i)$ - вага синапса, $i = 1, n$;

x - компонент вхідного вектора, $i = 1, n$;

b - значення зміщення;

n - число входів нейрона;

y - вихідний сигнал нейрона;

$f(s)$ - нелінійне перетворення (функція активації).

У загальному випадку вхідний сигнал, вагові коефіцієнти та зміщення

можуть набувати дійсних значень, а в багатьох практичних завданнях - деякі фіксовані значення. Вихід визначається видом функції активації, і може бути як дійсним, так і цілим.

2 ДОСЛІДЖЕННЯ ІСНУЮЧИХ МЕТОДІВ РОЗПІЗНАВАННЯ МЕДИЧНИХ ЗОБРАЖЕНЬ

Останніми роками методи розпізнавання медичних зображень з використанням штучного інтелекту (ШІ) зазнали бурхливого розвитку, ставши незамінними інструментами в різних галузях медицини.

У моїй роботі наведено систематичний огляд літератури щодо моделей на основі штучних нейронних мереж (ANN) для діагностики раку молочної залози. Переваги та обмеження різних моделей ANN, включаючи нейронну мережу з шипами (SNN), мережу глибокого переконання (DBN), згорткову нейронну мережу (CNN), багат шарову нейронну мережу (MLNN), багаторівневі автоенкодері (SAE), на рис. 2.1 показано вибірку ANN, що складається з вхідного, прихованого і вихідного шарів.

ANN - це алгоритм машинного навчання, придатний для різних завдань, включно з класифікацією, прогнозування та візуалізацією. Крім того, ANN підходить для розв'язання міждисциплінарних завдань із використанням декількох типів даних, які можуть бути неструктурованими, напівструктурованими і структурованими даними. Для медичних зображень раку молочної залози, які є формою неструктурованих даних, розглядаються неструктурованих даних, розглядаються неглибокі ANN і DNN (рис. 2.2, рис. 2.3).




Рис 2.1 - Приклад ANN прямого поширення

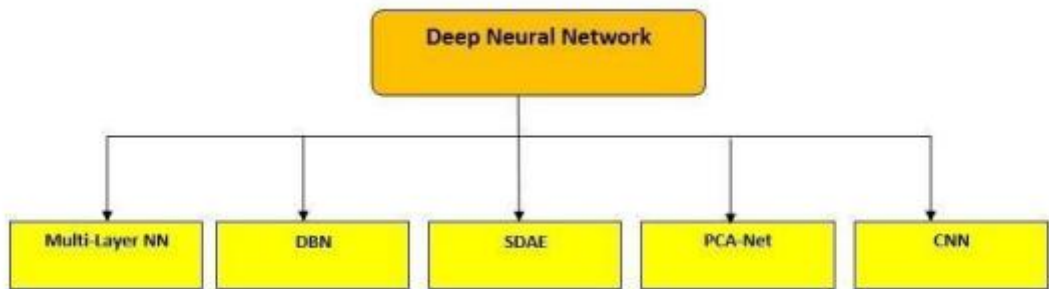


Рис 2.2 - Діаграма глибокої нейронної мережі DNN

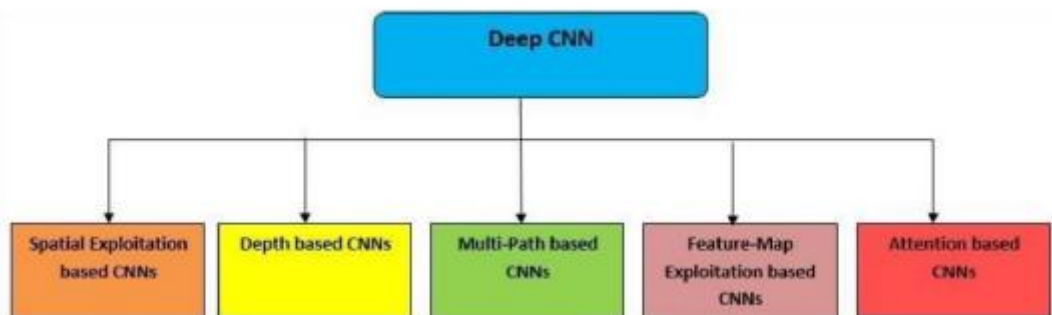


Рис 2.3 - схема глибокої згорткової нейронної мережі (CNNs)

З розвитком машин: ми помічаємо деякі основні переваги, такі як невеликий розмір мережі, менша кількість часу для навчання і менше пам'яті. Ми також помічаємо, що краща продуктивність може бути досягнута за допомогою додаткових прихованих шарів, але також ми можемо помітити деякі слабкі сторони, які не можуть забезпечити хороший результат, коли дані мають високу розмірність. Потім потрібно більше даних, щоб отримати хорошу продуктивність для додаткового прихованого шару. Коли дані мають високу розмірність, навчання моделі стає складнішим через так зване «прокляття розмірності». Це означає, що зі збільшенням розмірності даних, обсяг необхідної для навчання інформації зростає. У таких випадках просте додавання прихованих шарів може не призвести до поліпшення результатів, а навпаки, погіршити їх через перенавчання. Щоб впоратися з цими проблемами, розробники та дослідники часто вдаються до використання регуляризації та методів зниження розмірності, таких як головні компоненти аналізу (РСА) або метод незалежних компонент (ІСА). Регуляризація допомагає уникнути перенавчання, додаючи штраф за складність моделі, тоді як методи зниження розмірності зменшують кількість ознак, зберігаючи при цьому основну інформацію.

Крім того, сучасні підходи до машинного навчання часто включають використання ансамблевих методів, як-от випадкові ліси або градієнтний бустинг, які можуть підвищити точність моделі. Ці методи працюють за рахунок комбінування декількох моделей для поліпшення загального результату.

2.1 Згорткові нейронні мережі

Згорткова нейронна мережа (CNN) - це клас глибоких штучних нейронних мереж прямого поширення, які успішно застосовуються для аналізу візуальних зображень з високим ступенем інваріантності до масштабування, переміщення, обертання, ракурсів та інших просторових спотворень. Метою CNN є глибоке

дослідження даних за допомогою згорток. Вони ефективно розпізнають об'єкти на зображеннях, а також успішно виконують завдання класифікації. CNN здатні розпізнавати широкий спектр візуальних даних, включаючи обличчя, вуличні знаки, собак та інші об'єкти. Крім того, їх застосовують для аналізу тексту за допомогою оптичного розпізнавання символів.

CNN, як правило, найбільш ефективні, коли у вхідних даних простежується деяка структура. Прикладом може слугувати, як зображення, так і аудіодані, що мають набір повторюваних шаблонів, і вхідні значення, що надходять один з одним, мають якийсь просторовий зв'язок.

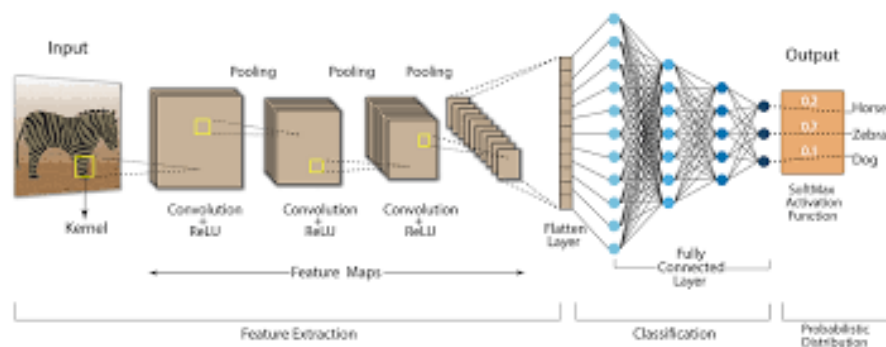


Рис 2.4 – Візуалізація роботи CNN

CNN перетворюють вхідні дані, що надходять на вхідний шар, проводячи їх через усі під'єднані шари в набір оцінок класів, що задаються вихідним шаром. Існує багато варіантів архітектур CNN, але всі вони засновані на архітектурі, представленій на малюнку 2.5 На ньому показано три основні групи шарів:

1. Вхідний шар (input layer).
2. Ознаковий шар (feature-extraction layer).
3. Класифікатор (Classification layer).

Структура вхідних даних зазвичай має тривимірний вигляд: ширина, висота зображення, а також глибина, що являє собою колірні канали (наприклад, три для колірної моделі RGB).

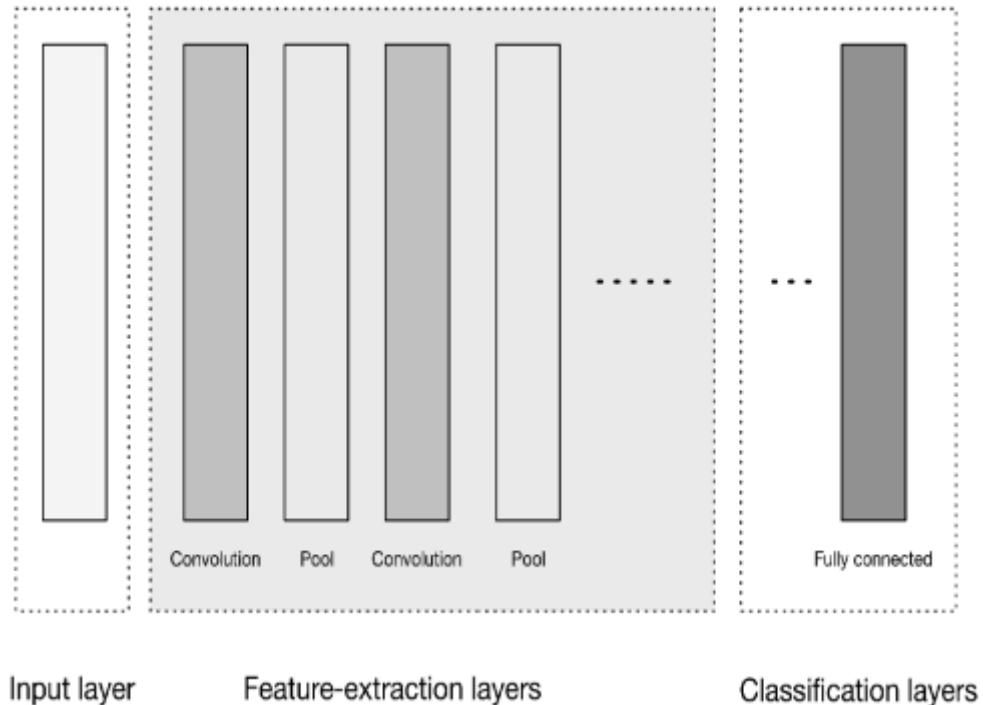


Рис 2.5 – Загальна архітектура CNN високого рівня

Вхідний шар - це місце, де ми завантажуюємо і зберігаємо вихідні та вхідні дані зображення для їх подальшого оброблення мережею. Вхідні дані визначають ширину, висоту і кількість каналів шару. Шари виділення ознак мають загальну повторювану структуру, Шар згортки, Шар пулу. Ці шари знаходять ознаки на зображеннях поступово складаючи карти. Шар класифікації складається з єдиного або кількох повнозв'язних шарів, для диференціювати карти ознак і обчислення ймовірності їхньої приналежності до заданих класів. Розміри вихідних даних шару дорівнюють: $[1 \times 1 \times N]$, де N - кількість оцінюваних класів. Згорткові шари вважаються основними будівельними блоками архітектур CNN. Згорткові шари перетворюють вхідні дані, використовуючи латочку з локально пов'язаних нейронів попереднього шару. Шар обчислюватиме скалярний добуток між областю

нейронів у вхідному шарі та вагами, з якими вони локально пов'язані у вихідному шарі.

Згортка - це математична операція, яка описує правило об'єднання двох наборів інформації. Операція згортки, зображена на рисунку 2.6, відома як детектор ознак згорткової нейронної мережі (CNN). На вхід згортки можна подавати або необроблені дані, або результати іншої згортки. Її часто інтерпретують як фільтр, в якому ядро фільтрує вхідні дані для певних типів інформації.

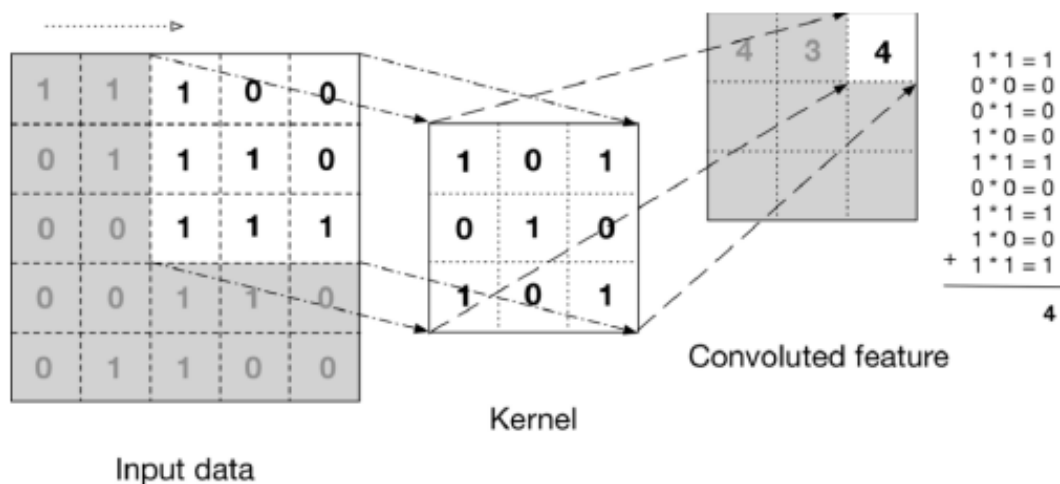


Рис 2.6 – Операція згортки

На малюнку показано, як ядро ковзає по вхідних даних для отримання даних із заплутаними характеристиками (висновками). На кожному кроці ядро множиться на значення вхідних даних у межах його кордонів, створюючи єдиний запис на вихідній карті ознак. Уведемо поняття оператора згортки. Маючи двовимірне зображення I і невелику матрицю K розмірності $h \times w$ (так зване ядро згортки), побудована таким чином, що графічно кодує будь-яку ознаку, ми обчислюємо згорнуте зображення $I * K$, накладаючи ядро на зображення усіма можливими способами і записуючи суму добутків елементів вихідного зображення і ядра:

$$(I * K)_{xy} = \sum_{i=1}^h \sum_{j=1}^w K_{ij} \times I_{x+i-1,y+j-1}$$

Формула 2.1 - Математичне рівняння, яке описує операцію згортки

де:

I - двовимірне зображення;

K - ядро згортки;

$I * K$ - шукане згорнуте зображення;

x, y, h, w - індекси матриць.

Оператор згортки становить основу згорткового шару у CNN. Шар складається з певної кількості ядер k (з адитивними складовими зміщення b для кожного ядра) і обчислює згортку вихідного зображення попереднього шару за допомогою кожного з ядер, щоразу додаючи складову зміщення. Зрештою до всього вихідного зображення може бути застосована функція активації σ . Зазвичай вхідний потік для згорткового шару складається з d каналів, наприклад, red/green/blue для вхідного шару, і в цьому разі ядра теж розширюють таким чином, щоб вони також склалися з d каналів; виходить наступна формула для одного каналу вихідного зображення згорткового шару, де K - ядро, а b - складова зміщення:

$$\text{conv}(I, K)_{x,y} = \sigma(b + \sum_{i=1}^h \sum_{j=1}^h \sum_{k=1}^d K_{ijk} \times I_{x+i-1,y+j-1,k})$$

Формула 2.2 - Математичне рівняння, яке описує операцію згортки

де:

σ - функція активації;

K - ядро згортки;

b - складова зміщення.

2.2 Класифікатори, засновані на обробці простору характеристик

2.2.1 Логістична регресія

Логістична регресія - це статистичний метод моделювання, який використовується для розв'язання задач класифікації, особливо бінарної класифікації, коли результуюча змінна приймає два можливі значення: 0 або 1, «так» або «ні», «успіх» або «невдача». Логістична регресія оцінює ймовірність того, що конкретна подія відбудеться, використовуючи один або кілька незалежних змінних. (Рис 2.7)




Рис 2.7 – Графік логістичної регресії

Основні концепції логістичної регресії:

1. Логістична функція (сигмоїда):

Центральним елементом логістичної регресії є логістична функція або сигмоїдальна функція, яка перетворює лінійну комбінацію вхідних змінних у значення ймовірності. Формула логістичної функції:

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

$$\text{де } z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n.$$

Формула 2.3 - Формула логістичної функції

2. Ймовірність та лінійна комбінація:

У логістичній регресії лінійна комбінація пояснювальних змінних використовується для оцінки логіт-функції (логарифмічного шансу):

$$\text{logit}(P) = \log\left(\frac{P}{1-P}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$

де P — ймовірність належності об'єкта до класу 1.

Формула 2.4 - рівняння, яке описує логістичну регресію (логіт-функцію)

3. Оцінка параметрів (коефіцієнтів):

Параметри моделі (коефіцієнти $\beta_0, \beta_1, \dots, \beta_n$) оцінюються за допомогою методу максимальної правдоподібності. Мета полягає в тому, щоб знайти такі значення параметрів, які максимізують функцію правдоподібності, що визначає ймовірність спостереження наявних даних за даної моделі.

4. Функція втрат:

Функція втрат у логістичній регресії базується на логарифмічній функції втрат (Log Loss або Cross-Entropy Loss), яка вимірює невідповідність між передбаченими ймовірностями та фактичними мітками:

$$L(\beta) = -\frac{1}{m} \sum_{i=1}^m [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]$$

де y_i — справжнє значення, а \hat{y}_i — передбачена ймовірність.

Формула 2.5 – Функція втрат

2.2.2 Метод k-ближчих сусідів (k-NN)

Метод k-ближчих сусідів (k-NN) — це простий і ефективний алгоритм машинного навчання, який використовується для задач класифікації та регресії. Алгоритм працює на основі аналогії з відомими точками даних і не робить жодних припущень про розподіл даних. Він належить до категорії методів навчання без учителя, оскільки не буде явної моделі навчання, а зберігає всю навчальну вибірку для подальшого використання під час класифікації або регресії. (Рис 2.8)




Рис 2.8 - ілюстрація роботи алгоритму k-ближчих сусідів (k-NN) для задачі класифікації.

Рис. 2.8. складається з трьох частин, кожна з яких демонструє різні аспекти роботи алгоритму.

1. Ліва частина:

На графіку зображено точки двох класів: клас 1 (сині кола) та клас 2 (зелені кола). Фіолетова точка вказує на "цільову точку", яку потрібно класифікувати.

2. Середня частина:

Показано, як алгоритм визначає найближчих сусідів цільової точки. Чорні пунктирні лінії вказують на відстані від цільової точки до її k найближчих сусідів (в даному випадку, здається, $k = 3$).

3. Права частина:

Навколо цільової точки накреслено коло, яке охоплює її найближчих сусідів. Показує, як алгоритм k -NN обчислює відстані до найближчих сусідів і приймає рішення про класифікацію на основі більшості класів серед цих сусідів.

На основі цього прикладу можна пояснити, як працює алгоритм k -NN:

Алгоритм знаходить k найближчих сусідів цільової точки, обчислюючи відстані до всіх точок у навчальній вибірці. Потім класифікує цільову точку на основі міток класів її k найближчих сусідів шляхом голосування: цільова точка відноситься до класу, який має більшість серед сусідів. В цьому випадку, якщо більшість із найближчих сусідів цільової точки належать до класу 1, то цільова точка буде класифікована як клас 1; якщо більшість належать до класу 2, то цільова точка буде класифікована як клас 2.

Основні концепції k-NN. Ідея алгоритму:

Алгоритм визначає клас або значення для нового об'єкта, ґрунтуючись на найближчих k сусідах з навчальної вибірки. Використовує метрики відстані для визначення схожості між точками даних.

Метрика відстані:

Найпоширеніша метрика відстані — це евклідова відстань:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Формула 2.6 – евклідова відстань

де x і y — дві точки в n -вимірному просторі.

Інші метрики включають манхеттенську відстань, косинусну подібність та інші, залежно від характеру даних.

Вибір параметра k :

Параметр k визначає кількість найближчих сусідів, які враховуються під час класифікації або регресії. Значення k впливає на результат: маленьке k може призвести до переобучення (низької стабільності), велике k може призвести до недообучення (втрата деталей).

Процес класифікації з використанням k-NN

- Збір даних:

Отримання навчальної вибірки з відомими мітками класів.

- Обчислення відстаней:

Для кожного нового об'єкта обчислюється відстань до всіх точок у навчальній вибірці.

- Вибір k найближчих сусідів:

Вибираються k точок з найменшою відстанню до нового об'єкта.

- Голосування за клас:

Класи нових об'єктів визначаються більшістю голосів їхніх k найближчих сусідів. Об'єкт відноситься до класу, який найчастіше зустрічається серед сусідів.

Процес регресії з використанням k -NN

- Збір даних:

Отримання навчальної вибірки з відомими значеннями цільової змінної.

- Обчислення відстаней:

Для кожного нового об'єкта обчислюється відстань до всіх точок у навчальній вибірці.

- Вибір k найближчих сусідів:

Вибираються k точок з найменшою відстанню до нового об'єкта.

- Агрегація значень:

Прогнозне значення для нового об'єкта обчислюється як середнє або зважене середнє значення цільової змінної його k найближчих сусідів.

2.2.3 Метод опорних векторів (SVM)

Метод опорних векторів - це новий підхід до контрольованої класифікації шаблонів, який було успішно застосовано до широкого спектру завдань розпізнавання образів, а також алгоритм навчання для вивчення правил класифікації та регресії на основі даних. SVM найбільш підходить для точної та ефективної роботи з просторами об'єктів високої розмірності на додаток до того, що SVM заснована на сильних математичних обчисленнях і дає прості та дуже потужні алгоритми. Стандартний алгоритм SVM будує двійковий класифікатор. Простий спосіб побудувати двійковий класифікатор - побудувати гіперплощину, що відокремлює членів класу від нечленів у вхідному просторі. SVM також знаходить нелінійну функцію прийняття рішень у вхідному просторі, відображаючи дані в простір об'єктів більш високої розмірності та розділяючи їх за допомогою гіперплощини з максимальним запасом. Система автоматично ідентифікує підмножину інформативних точок, званих опорними векторами, і використовує їх для представлення тих, що розділяють. Підпорядковується D_{ii} , де відповідає міткам класу, який приймає значення $+1$ і -1 . Примірники з ненульовими вагами називаються опорними векторами. У той час, коли їх було розроблено, SVM демонстрував найсучаснішу сучасну продуктивність у простих завданнях класифікації і був одним із небагатьох методів машинного навчання, підкріплених великою теорією і піддавався серйозному математичному аналізу, що робило їх добре зрозумілими і легко інтерпретованими. Через ці корисні властивості, SVM стали надзвичайно популярними в цій галузі протягом тривалого часу. Але SVM виявилось важко масштабувати до великих наборів даних і не давало хороших результатів для таких перцептивних проблем, як класифікація зображень. Оскільки SVM - це неглибокий метод, застосування SVM до проблем сприйняття вимагає спочатку вилучення корисних уявлень вручну (крок, званий розробкою функцій), що є складним і крихким.




Рис 2.9 - принцип роботи методу опорних векторів (SVM)

Метод опорних векторів (SVM) є потужним і популярним алгоритмом для задач класифікації, особливо ефективним для лінійно роздільних даних. Він знаходить оптимальну гіперплощину, яка максимізує зазор між класами, що забезпечує високу здатність до узагальнення на нових даних.

2.2.4 HD-CNN

Глибока (Hierarchical Deep CNN) згорткова ієрархічна мережа складається з наступних компонентів:

1. загальний компонент для базової обробки вхідних зображень
2. Компонент грубого виділення категорій
3. Компоненти точного виділення категорій (їх кількість дорівнює кількості кількості класів об'єктів)
4. Кінцевий усереднюючий шар

Принцип роботи полягає в тому, що загальні шари використовують вихідне зображення для вилучення низькорівневих зображення з метою вилучення

низькорівневих ознак. Далі, шари екстракції грубих категорій, які мають схожу конфігурацію із загальними шарами, використовують витягнуті ознаки для створення із загальними шарами, використовують витягнуті ознаки для проміжного прогнозування проміжного прогнозування грубих категорій, які в подальшому будуть використані як ваги для об'єднання прогнозів компонентів точних компонентів точної категорії. Блоки точної категоризації, які використовуються для прогнозування точних категорій, використовують низькорівневі ознаки, витягнуті з загальних шарами, з урахуванням ваг, отриманих блоком прогнозування грубих категорій. По суті, кожен з цих блоків виконує бінарну класифікацію, результатом якої є - чи належить об'єкт до певної категорії. Шар усереднення, який приймає як точні, так і грубі прогнози категорій і виробляє остаточний прогноз на основі середньозваженого значення (рис. 2.10).

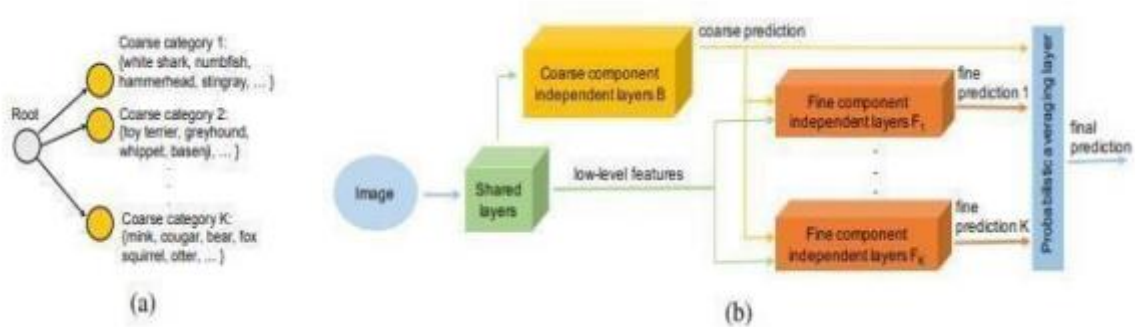


Рис 2.10 – Схема архітектури HD-CNN

В якості блоків даної моделі, можуть бути обрані реалізації популярних згорткових блоків сучасних моделей. Навчання моделі проводиться таким чином. Попередньо навчається загальний блок на всіх даних з використанням точних міток. Блок грубих компонент навчається з використанням грубих міток. Блоки точного налаштування навчаються тільки на підвибірках, що належать до певної точної категорії з мітками про приналежність до цього класу. Потім проводиться налаштування шару усереднення, коли всі переднавчені блоки об'єднані в загальну модель.

3 ПРАКТИЧНА РЕАЛІЗАЦІЯ

Реалізація була проведена з використанням мови Python (рис 3.1). Для всіх моделей використовували переднавчені ваги, на основі датасету ImageNet (рис 3.2).

ImageNet - це набір даних мільйонів помічених зображень із високою роздільною здатністю, що належать приблизно до 22 тисяч категорій. Зображення були зібрані з Інтернету і позначені людьми за допомогою краудсорсингу. Існує близько 1,2 мільйона навчальних образів, 50 тис. образів для валідації. образів для валідації 150 тис. тестових зображень.

Для попереднього опрацювання даних яскравість зображень було нормалізована відносно середніх значень усього датасету. Розмір зображень було змінено на 224x224 для зменшення обсягу необхідної пам'яті. Кожна з моделей навчалась у 3 епохи, як функцію активації вихідного шару використовували сигмоїду, як функцію втрат - бінарну крос ентропію.




Рис 3.1 – Логотип Python



Рис 3.2 - Датасет ImageNet

3.1 Алгоритми класифікації даних

Існує безліч алгоритмів машинного навчання, кожен з яких призначений для вирішення конкретних завдань. У цій роботі застосовуються алгоритми контрольованого машинного навчання, спрямовані на вирішення завдання.

3.2. Штучні нейронні мережі

Вивчаючи будову та зв'язок нейронів головного мозку, дослідники знайшли натхнення для того, щоб розробити архітектуру штучних нейронних мереж. Штучні нейронні мережі (ШНМ) існують уже досить давно: вони були вперше представлені ще в 1943 році нейрофізіологом Ворреном МакКаллохом і математиком Волтером Піттсом. Перші успіхи штучної нейронної мережі до 1960-х років, призвели до широко поширеного переконання, що скоро буде реально створити по-справжньому інтелектуальні машини. Коли стало зрозуміло, що це очікування не виправдалося (принаймні, на довгий час), фінансування проєктів припинилося, і штучні нейронні мережі були забуті на кілька років. Незодавно ШНМ пережили своє відродження, завдяки «глибокому навчанню». Незважаючи на те, що глибоке навчання обіцяє великі перспективи в різних сферах застосування машинного навчання, алгоритми глибокого навчання, як правило, жорстко

прив'язані до конкретних випадків використання. Розглянемо модель багат шарового персептрона, представлену на малюнку 3.3.




Рис. 3.3 - Модель багат шарового персептрона

У цієї моделі набагато більше обчислюваних коефіцієнтів (також званих вагами): коефіцієнт між кожним входом і кожним прихованим елементом (які утворюють прихований шар або hidden layer) і коефіцієнт між кожним елементом прихованого шару і виходом. З математичної точки зору обчислення серії зважених сум - це те саме, що обчислення лише однієї зваженої суми, таким чином, щоб ця модель володіла (MLP), їх також називають простими нейронними мережами прямого поширення, а іноді й просто нейронними мережами. MLP можна розглядати як узагальнення лінійних моделей, яке

перш ніж прийти до рішення, виконує кілька етапів опрацювання даних. У лінійній регресії прогноз отримують за допомогою такої формули:

$$\hat{y} = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$$

Формула 3.1 – Формула отримання прогнозу

де \hat{y} - прогнозоване значення, w_0 - вільний член (константа), w_1, w_2, \dots, w_n - ваги, які визначають вплив відповідних ознак x_1, x_2, \dots, x_n на прогнозоване значення. Ця модель є лінійною, оскільки прогнозоване значення є лінійною комбінацією ознак.

MLP складається з одного (проміжного) вхідного рівня, одного або декількох шарів лінійних порогових елементів (персептронів), званих прихованими рівнями, і одного кінцевого рівня лінійних порогових елементів, званих вихідним рівнем. Кожен шар, крім вихідного, має нейрон зсуву і повністю пов'язаний із наступним шаром.

Коли ШНМ має два або більше прихованих шари, вона називається глибокою нейронною мережею, більш потужною прогнозною силою, ніж лінійна модель, нам потрібен один додатковий трюк. Пояснимо його на прикладі нейронної мережі з одним прихованим шаром. Вхідний шар просто передає входи прихованому шару мережі, або без перетворення, або виконавши спочатку стандартизацію входів.

Потім відбувається обчислення зваженої суми входів для кожного елемента прихованого шару, до неї застосовується функція активації - зазвичай використовуються нелінійні функції випрямлений лінійний елемент (rectified linear unit або relu) або гіперболічний тангенс (hyperbolic tangent або tanh). У підсумку отримуємо виходи нейронів прихованого шару.

Ці проміжні виходи можна вважати нелінійними перетвореннями та комбінаціями початкових входів. Вони стають входами вихідного шару. Знову обчислюємо зважену суму входів, застосовуємо функцію активації і отримуємо підсумкові значення цільової змінної. Функції активації relu і tanh як показано на Рисунку 3.4. Relu відсікає значення нижче нуля, тоді як tanh приймає значення від -1 до 1 (відповідно для мінімального і максимального значень входів). Будь-яка з цих двох нелінійних функцій дозволяє нейронній мережі на відміну від лінійної моделі обчислювати набагато складніші залежності.




Рис 3.4 - Функції активації прихованого рівня

Однією з головних переваг штучних нейронних мереж (ШНМ) є їхня здатність обробляти величезну кількість даних і будувати складні моделі. За наявності достатнього обчислювального часу, даних, і ретельного налаштування параметрів, нейронні мережі часто демонструють високу продуктивність порівняно з іншими алгоритмами машинного навчання (для задач класифікації та регресії).

Цей підхід, однак, не позбавлений недоліків. Як правило, нейронні мережі, особливо великі нейронні мережі, потребують тривалого періоду навчання та ретельної попередньої обробки даних. Крім того, процес налаштування параметрів нейронної мережі є важливим аспектом побудови моделі.

Для створення нейромережевої моделі для користувачів Python було розроблено декілька бібліотек, найбільш відомими з яких є Keras, Lasagna та TensorFlow. Ці бібліотеки пропонують гнучкий інтерфейс для побудови нейронних мереж і

оновлюються з урахуванням останніх досягнень у галузі глибокого навчання. У цій роботі для побудови ШНМ було використано бібліотеку Keras (Рис 3.5).



Рис 3.5 – Логотип Keras

Перед побудовою моделі штучної нейронної мережі необхідно визначити її архітектуру, включаючи кількість шарів та кількість нейронів у кожному шарі. Keras пропонує два різних методи для визначення нейронної мережі: клас послідовної моделі та функціональний API (Рис 3.6).




Рис 3.6 – Functional API

Обидва мають спільну мету - визначити нейронну мережу, але використовують різні методології. У цій роботі було використано клас Sequential model (Рис 3.7).




Рис 3.7 - Sequential API

Клас Sequential використовується для визначення лінійного стеку рівнів, які разом складають модель. Далі відбувається конфігурація процесу навчання в блоці компіляції, де встановлюються три основні параметри: функція втрат, оптимізатор

і метрика. Функція втрат слугує для оцінки точності моделі під час навчання. Важливо мінімізувати значення цієї функції, щоб "вести" модель у потрібному напрямку. Оптимізатор відповідає за оновлення моделі на основі вхідних даних і функції втрат. Метрики вказують на кроки навчання та тестування моделі, а також на те, яка метрика використовується для оцінки кількості спостережень, що були класифіковані правильно. У контексті навчання моделі особливе значення мають два ключові параметри: розмір партії, який визначає кількість прикладів, що подаються на модель за один раз, і кількість епох для навчання. Епоха визначається як один повний прохід навчальної вибірки через модель. Від правильного налаштування цих параметрів значною мірою залежить якість результату роботи штучної нейронної мережі.

3.3 Оцінка якості класифікації

У задачі бінарної класифікації, що розглядається в цій статті, передбачається, що є два класи: позитивний (positive) і негативний (negative). Позитивний клас - це той, який потрібно прогнозувати.

У контексті скринінгових обстежень для раннього виявлення раку результати автоматизованого тесту будуть інтерпретуватися наступним чином: якщо тест негативний, пацієнт буде вважатися здоровим; якщо тест позитивний, пацієнт буде підданий додатковому скринінгу. Практично неможливо бути впевненим, що модель працюватиме бездоганно, вона неминуче буде припускатися помилок. Тому важливо чітко уявляти собі наслідки помилок у реальному світі.

Можливі два типи помилок: помилка I типу, яка являє собою хибнопозитивний результат (тест виявив хворобу, але людина здорова – false positive), і помилка II типу, яка являє собою хибнонегативний результат (тест не виявив хворобу, але людина насправді хвора – false positive). На перший погляд, найнебезпечніша помилка II типу полягає в тому, що людина не отримає вчасно лікування. Однак помилка I типу також призводить до неприємних наслідків, про які частково

йшлося у Розділі 1 цієї роботи. До них належать стрес і витрати на додаткові обстеження, гіпердіагностика, лікування, яке людині не потрібне і яке може бути шкідливим, а також заподіяння шкоди. Тому доцільно зосередитися на мінімізації обох типів помилок. Одним з найпопулярніших методів оцінки якості бінарної класифікації є використання матриці помилок. Це таблиця 2x2, де рядки відповідають фактичним класам, а стовпці - прогнозованим класам.

Елементи головної діагоналі матриці помилок відповідають правильним прогнозам (результатам класифікації), а решта елементів показують, скільки прикладів, що належать до одного класу, були помилково віднесені до іншого класу. Правильно класифіковані позитивні приклади називаються істинно позитивними, тоді як решта елементів показують кількість прикладів одного класу, які були помилково віднесені до іншого. І навпаки, позитивні приклади називаються істинними негативами, а правильно класифіковані негативні приклади називаються істинними позитивами. Ці чотири терміни зазвичай скорочують як FP (false positive), FN (false negative), TP (true positive) і TN (true negative), і вони дають наступну інтерпретацію матриці помилок (Рис 3.8).

TN	FP
FN	TP

Рис 3.8 – Матриця помилок

Фактично негативний клас. Фактично позитивний клас на основі даних матриці помилок обчислюються такі показники якості класифікації. Правильність (або загальна точність, accuracy) - це кількість вірно класифікованих прикладів (TP і TN), поділена на загальну кількість прикладів (усі елементи матриці помилок):

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

Формула 3.2 - формула для обчислення правильності класифікації в контексті машинного навчання

Цей захід якості застосовується тоді, коли класи збалансовані. У цій роботі досліджується набір даних зі збалансованими класами, тому ця міра застосовна для оцінювання та порівняння роботи моделей. Точність (precision) показує, скільки з передбачених позитивних прикладів виявилися справді позитивними. Таким чином, точність - це частка істинно позитивних прикладів від загальної кількості передбачених позитивних прикладів, вона використовується як показник якості моделі, коли мета полягає в тому, щоб знизити кількість хибно позитивних прикладів (тобто помилку I роду).

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

Формула 3.3 - формула для обчислення точності класифікації в контексті машинного навчання

Фактичних позитивних прикладів. Повноту використовують як показник якості моделі, коли необхідно визначити всі позитивні приклади, тобто, коли важливо знизити кількість хибно негативних прикладів (знизити помилку II роду).

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

Формула 3.4 - формула для обчислення повноти класифікації в контексті машинного навчання

Хоча точність і повнота є важливими метриками, окремо вони не дають вичерпної оцінки. Одним із способів узагальнити результат є F-міра (F-measure), яка являє собою гармонійне середнє точності та повноти.

$$F - \text{МІРА} = 2 \times \frac{\text{ТОЧНІСТЬ} \times \text{ПОВНОТА}}{\text{ТОЧНІСТЬ} + \text{ПОВНОТА}}$$

Формула 3.5 – Обчислення F-міри

У разі бінарної класифікації незбалансованих даних вона може бути кращою метрикою, ніж правильність.

Ще один інструмент, який зазвичай використовують для аналізу поведінки класифікаторів за різних порогових значень (величина ймовірності, за якої об'єкт буде віднесено до позитивного класу) - це крива робочої характеристики приймача (receiver operating characteristics curve) або коротко ROC-крива (ROC curve). ROC-крива дає змогу розглянути всі порогові значення для даного класифікатора, вона показує частку хибно позитивних прикладів (false positive rate, FPR) у порівняно з часткою істинно позитивних прикладів (true positive rate). Частка істинно позитивних прикладів - це ще одна назва повноти, тоді як частка хибно позитивних прикладів - це частка хибно позитивних прикладів від загальної кількості негативних прикладів.

$$FPR = \frac{FP}{FP + TN}$$

Формула 3.6 - обчислення частоти хибнопозитивних результатів

Ідеальна ROC-крива проходить через лівий верхній кут, відповідаючи класифікатору, який дає високе значення повноти за низької частки хибно позитивних прикладів. Приклад (не ідеальної) ROC-кривої наведено на Рис 3.9.

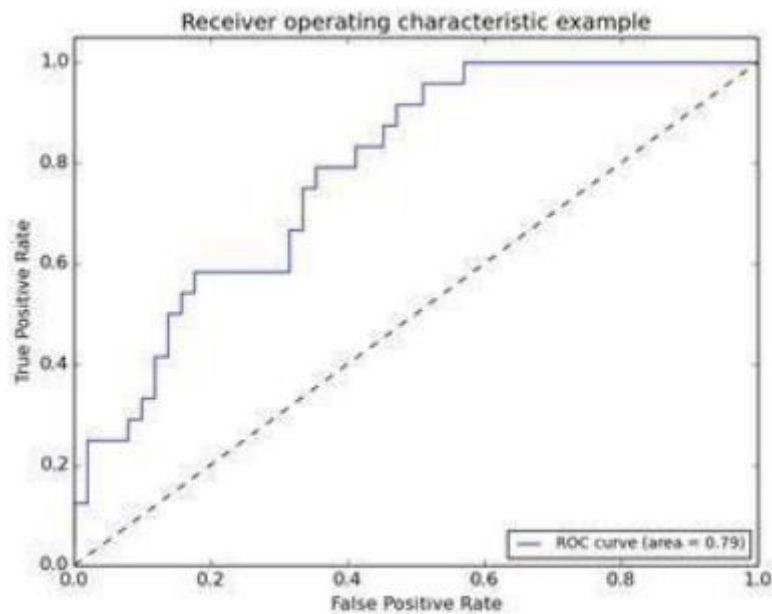


Рис 3.9 - ROC-крива

Щоб підбити підсумок роботи моделі, використовують величину AUC (Area under ROC-curve) - площа під ROC-кривою. Чим більше AUC, тим якісніша класифікація. Значення площі під кривою еквівалентно ймовірності того, що згідно з побудованою моделлю випадково обраний приклад позитивного класу матиме вищий бал, ніж випадково обраний приклад негативного класу. Таким чином, ідеальне значення AUC, що дорівнює 1, означає, що всі позитивні приклади на відміну від негативних мають вищий бал.

3.4 Проведення експериментів

Для того, щоб ідентифікувати і класифікувати тип пухлини молочної залози кожної пацієнтки, лікарі зазвичай звертаються до зображення і складають звіт про аналіз обстежень пацієнтки. Описаний метод допоможе лікарю діагностувати пухлину молочної залози пацієнтки. Після того, як система буде встановлена, лікар може протестувати її з деякими відомими даними, а потім використати ці дані для створення звіту про дослідження пацієнта.

Якість зображень, отриманих з медичних пристроїв, може впливати на результат обробки (аналізу) при вирішенні діагностичних медичних проблем. У більшості випадків отримані зображення (або набори зображень) мають помітний рівень шуму, зумовлений технологічними особливостями роботи приладів. З огляду на це, автори пропонують наступну процедуру обробки медичних зображень (рис. 3.10).

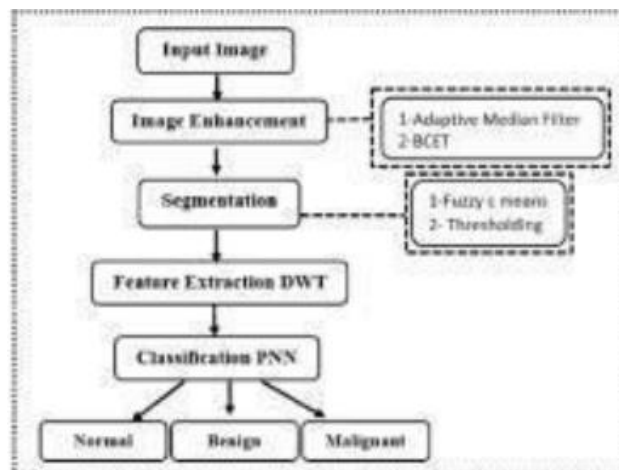


Рис 3.10 - блок-схема процесу обробки медичних зображень

Отримані зображення конвертуються у формат відтінків сірого. Потім виконується серія обчислювальних кроків:

Input Image (Вхідне зображення) - Початковий етап, де завантажується вхідне медичне зображення.

Image Enhancement (Покращення зображення) - Застосування методів покращення зображення для поліпшення якості.

Використовуються:

- Adaptive Median Filter (Адаптивний медіанний фільтр) для зменшення шуму.
- BBET (Bi-Histogram Equalization Technique) для покращення контрастності.

Segmentation (Сегментація) - Розділення зображення на сегменти для виділення цікавих областей.

Використовуються методи:

- Fuzzy c-means (Нечітке c-середнє) для кластеризації пікселів.
- Thresholding (Порогове значення) для відокремлення об'єктів від фону.

Feature Extraction DWT (Виділення ознак з використанням DWT) - Застосування дискретного вейвлет-перетворення (DWT) для виділення ознак зображення.

Classification PNN (Класифікація за допомогою PNN) - Класифікація виділених ознак за допомогою ймовірнісної нейронної мережі (PNN). На цьому етапі зображення класифікується як нормальне, доброякісне або злоякісне.

Частина зображення, що містить пухлину, зазвичай інтенсивніша, ніж інша частина. Основні кроки з виявлення пухлини описані в коді.

Одночасно з цим для області, що має приблизно такий самий вміст, як і об'єкт, що цікавить, можлива додаткова обробка залежно від факторів необхідного аналізу. Залежно від медичного завдання, колірне кодування може застосовуватися в області, що цікавить, і в її околицях для аналізу стану медичної області та в її околицях для аналізу стану тканин тощо. Кольорове кодування дає змогу

візуалізувати тонкі особливості структури тканин поблизу пухлини, що необхідно для подальших діагностичних процедур і порівняння з наявними матеріалами.

3.5 Покращення зображення

Основною метою цих фільтрів є зменшення шуму, хоча вони також можуть бути використані для підкреслення певних особливостей зображення. Адаптивний медіанний фільтр (AMF) класифікує пікселі як шум, порівнюючи кожен піксель зображення з сусідніми пікселями. Розмір, а також поріг порівняння можна регулювати. Піксель, який відрізняється від більшості своїх сусідів, а також структурно не відповідає пікселям, на які він схожий, позначається як імпульсний шум. Потім ці шумові пікселі замінюються середнім значенням пікселя для пікселів в оточенні, які пройшли тест на шумове маркування. Зображення спочатку конвертується у відтінки сірого за допомогою функції `rgb2gray`. Потім до отриманого зображення застосовується адаптивна середня фільтрація, після чого зображення перетворюється в беззнакове ціле число 8 за допомогою функції `uint8`.

Щоб поліпшити контраст для виділення області, було запропоновано використання Balance Contrast Enhancement (Рис 3.11), методика (BCET). Зазвичай під час обробці медичного зображення, потрібне посилення контрасту для області, що становить інтерес. Наприклад, Contrast Limited Adaptive (Рис 3.12), зрівнювання гістограми (CLANE) дає змогу поліпшити особливості та отримати кращі характеристики медичних зображень для правильної постановки діагнозу.




Рис 3.11 – Техніка покращення балансового контрасту (BCET).




Рис 3.12 - Результат вирівнювання адаптивної гистограми з обмеженим контрастом

3.6. Результати




Рис 3.13 – Використання методів інтенсивності, та зіставлення рівнів сірого

Диференціація нормальних і пухлинних клітин також полегшує розрахунок площі уражених ділянок пухлини. Розрахована площа визначається в пікселях. Для визначення площі пухлини використовується дискретне вейвлет-перетворення. В якості матричних (GLCM) методів використовуються методи на основі інтенсивності та методи зіставлення рівнів сірого (Рис. 3.13). На основі інтенсивності методу можна визначити середнє значення, а також стандартне відхилення. Методи GLCM допомагають визначити енергію, ентропію, контраст, кореляцію, однорідність і гладкість. Описаний тут метод є більш ефективним для сегментації пухлинної ділянки, ніж інший. У випадку, коли методи, включають деяку непухлинну область в кінцеве сегментоване зображення, наш метод визначає область пухлини, локалізує область пухлини на вихідному вхідному зображенні, і успішно відображає кольоровий результат. Кінцевий результат запропонованого методу показано на рис. 3.14, де у верхньому рядку представлено вихідні зображення (цифрова база даних для скринінгової мамографії (DDSM)).

Другий рядок представляє результат застосування покращеного зображення, описаного в розділі 2 цієї статті. Третій рядок - результат маскуваннн та обробки (кінцеве контурне зображення).




Рис. 3.14 - (а) Вхідні зображення; (б) Попередньо оброблені зображення, (в) Результати сегментації та класифікації різних типів пухлин грудей

Для оцінки надійності та точності виявлення пухлин молочної залози, отриманих запропонованим методом, використовувалися такі параметри: інтенсивнісні характеристики, середнє значення, стандартне відхилення (SD), матриця узгодження рівнів сірого (GLCM), енергія та ентропія. Відсоток пікселів, які були правильно виявлені, визначається за допомогою функцій на основі інтенсивності. Статистика першого порядку залежить виключно від значень окремих пікселів. Інтенсивність пікселів - це мамограма, яку пропонує метод.

Найпростіша доступна функція корисна для розпізнавання образів. Інтенсивність та її варіації в межах мамограми можуть бути використані такими характеристиками, як середнє значення та стандартне відхилення. Функції GLCM: Матриця зустрічальності рівнів сірого. Вимірювання текстури за допомогою матриці співпадіння рівнів сірого (GLCM) - це метод аналізу текстури зображення. Це надійний метод, розроблений для обчислення характеристик текстури, включаючи характеристики текстури першого і другого порядку для зображення.

Матриця GLCM - це таблиця частоти, з якою різні комбінації рівнів сірого зустрічаються на зображенні. Статистична текстура матриці відображається такими функціями, як середнє значення, стандартне відхилення (SD), контрастність, кореляція та однорідність. Підсмуги LH і HL перших п'яти рівнів вейвлету визначають декомпозицію. Енергія представляє впорядкованість мамографічного зображення. Функція енергії зазвичай представляє середній квадрат мамографічного зображення.

Ентропія: кількість аномалій у мамографічному дослідженні. Значення ентропії є високим у мікрокальцинатах. Зміна значення інтенсивності на зображенні висока через наявність білої плями кальцифікації. Найбільш часто використовуваною функцією ядра для PNN є радіальна базова функція (RBF) через локалізацію та скінченність відгуку у всьому діапазоні, який є дійсним по відношенню до осі абсцис. Точність класифікації ядра RBF була високою, а значення зсуву і частота

помилки ядра RBF також були відносно низькими порівняно з іншими ядрами (Рис. 3.15).

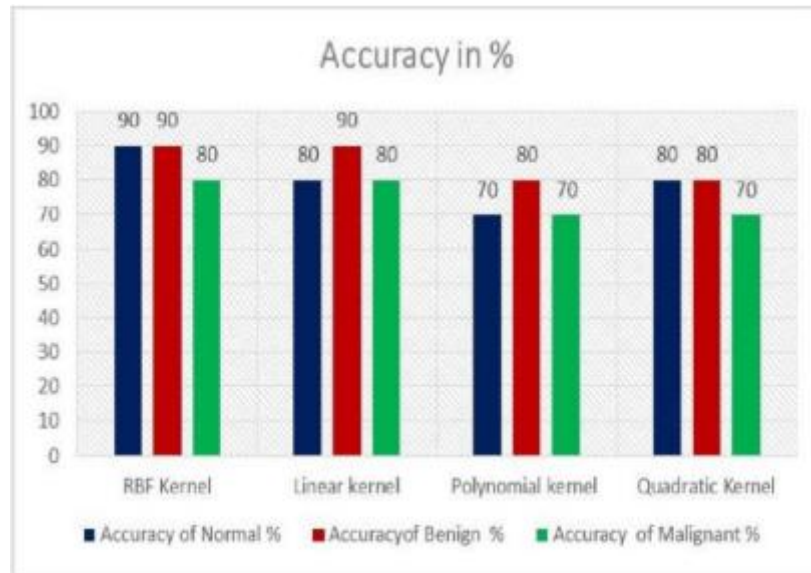


Рис 3.15 - графік точності

- RBF та Linear Kernels: Мають однакову точність для всіх трьох класів. Вони демонструють високу точність для Normal класу (90%) і добру точність для Benign та Malignant класів (80%).
- Polynomial Kernel: Має дещо нижчу точність у порівнянні з RBF та Linear Kernels, особливо для Benign та Malignant класів (70%).
- Quadratic Kernel: Показує хорошу точність для Normal та Benign класів (80%), але нижчу для Malignant класу (70%).

Цей графік дозволяє зробити висновок про те, що RBF та Linear Kernels є більш ефективними для цієї задачі класифікації в порівнянні з Polynomial та Quadratic Kernels.

3.7. Експериментальна реалізація

Початкова мережа була розроблена за допомогою TensorFlow, інструменту глибокого навчання, розробленого компанією Google. TensorFlow має відкритий вихідний код і пропонує інтерфейс на мові Python, що дозволяє легко побудувати згорткову нейронну мережу (CNN) і вказати її архітектуру, кількість і тип фільтрів, які будуть використовуватися, та інші параметри, які характеризують CNN. Крім того, Python полегшує та оптимізує обробку даних до та після ШНМ, оскільки дозволяє використовувати відповідні бібліотеки, такі як Pandas та NumPy.

Спочатку була побудована послідовна модель зі згортковою мережею одного виміру. Згодом базу було завантажено з бази даних MNIST, а перший шар було налаштовано як згортковий одновимірний шар (Conv1D). Ці згорткові шари працюватимуть із вхідними зображеннями, які розглядаються як одновимірні матриці як одновимірні матриці. `kernel_size=3` - розмір ядра 3. Функція активації 'relu' (Rectified Linear Activation), 64 - це число ядер згортки (скільки ознакою будемо шукати). Шари штучної нейронної мережі зазвичай визначаються групами по два, щоб забезпечити модель надійною основою для навчання ознак на основі вхідних даних.

Згорткові нейронні мережі (CNN) здатні швидко навчатися. Отже, основні шари були розроблені для уповільнення процесу навчання з метою створення більш оптимальної мережі. Шар злиття зменшує кількість вивчених ознак до однієї чверті (1/4) від їх початкового розміру, таким чином об'єднуючи лише найважливіші ознаки.

ВИСНОВКИ

У цій роботі було детально досліджено аналіз медичних зображень за допомогою штучних нейронних мереж. Було застосовано різні методи для класифікації зображень та тренування нейронних мереж з використанням різних моделей, зокрема Softmax і логістичної регресії, за допомогою бібліотеки Keras. Спостерігалось, як ці методи впливають на ROC-криву. Після навчання мережі отримані результати порівнювалися з даними з тестового набору.

Результати показали, що чим довше навчається модель нейронної мережі, тим точнішими стають її прогнози, наближаючись до 100%. Також було виявлено, що ROC-крива не впливає на характеристики моделі. На основі проведеного дослідження можна зробити висновок, що зі збільшенням обсягу вхідних даних кількість помилок, які робить модель, зменшується.

Точне розпізнавання медичних зображень є надзвичайно важливим для своєчасного лікування. У цьому дослідженні пропонується розробити систему для стандартної процедури виявлення раку молочної залози при діагностиці. Цифрова мамографія зараз є стандартним компонентом діагностичного процесу.

Для полегшення класифікації в галузі діагностики застосовуються різноманітні методи. Виділення особливостей зображення є ключовим етапом у класифікації мамограм. Ці ознаки виділяються шляхом застосування методів обробки зображень. Площа пухлини повинна бути розрахована за допомогою методу дискретного вейвлет-перетворення (DWT). Нормальні та ракові клітини відображаються окремо, а ентропія, середнє значення, стандартне відхилення, енергія, асиметрія та інші статистичні показники обчислюються на основі зображень у базі даних.

Запропонована нейронна мережа, яка класифікує зображення мамограм на три категорії: нормальні, доброякісні та злоякісні, з точністю понад 90%. Така система може бути корисною як для пацієнта, так і для лікаря.

ПЕРЕЛІК ВИКОРИСТАНИХ ПОСИЛАНЬ

1. Alizadehsani R., Habibi J., Hosseini M.J., Mashayekhi H., Boghrati R., Ghandeharioun A., Bahadorian B., Hesami S., “Diagnosis of coronary arteries stenosis using data mining”, *Journal of the American College of Cardiology*, vol. 5, no. 11, pp. 41-56, 2013.
2. Baldi P., Sadowski P., Whiteson D., “Searching for exotic particles in high-energy physics with deep learning”, *Nature Communications*, vol. 5, no. 4308, 2014.
3. Bengio Y., Courville A., Vincent P., “Representation learning: A review and new perspectives”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35, no. 8, pp. 1798-1828, 2013.
4. Bottou L., “Stochastic gradient learning in neural networks”, *Proceedings of Neuro-Nîmes*, 1991.
5. Deng J., Dong W., Socher R., Li L.J., Li K., Fei-Fei L., “ImageNet: A large-scale hierarchical image database”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 248-255, 2009.
6. Duchi J., Hazan E., Singer Y., “Adaptive subgradient methods for online learning and stochastic optimization”, *Journal of Machine Learning Research*, vol. 12, pp. 2121-2159, 2011.
7. Esteva A., Kuprel B., Novoa R.A., Ko J., Swetter S.M., Blau H.M., Thrun S., “Dermatologist-level classification of skin cancer with deep neural networks”, *Nature*, vol. 542, no. 7639, pp. 115-118, 2017.
8. Fukushima K., “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position”, *Biological Cybernetics*, vol. 36, no. 4, pp. 193-202, 1980.
9. Goodfellow I., Bengio Y., Courville A., “Deep Learning”, MIT Press, 2016.
10. He K., Zhang X., Ren S., Sun J., “Deep residual learning for image recognition”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770-778, 2016.

11. Hinton G.E., Salakhutdinov R.R., “Reducing the dimensionality of data with neural networks”, *Science*, vol. 313, no. 5786, pp. 504-507, 2006.
12. Krizhevsky A., Sutskever I., Hinton G.E., “Imagenet classification with deep convolutional neural networks”, *Advances in Neural Information Processing Systems*, vol. 25, pp. 1097-1105, 2012.
13. LeCun Y., Bottou L., Bengio Y., Haffner P., “Gradient-based learning applied to document recognition”, *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.
14. Litjens G., Kooi T., Bejnordi B.E., Setio A.A.A., Ciompi F., Ghafoorian M., van der Laak J.A.W.M., van Ginneken B., Sánchez C.I., “A survey on deep learning in medical image analysis”, *Medical Image Analysis*, vol. 42, pp. 60-88, 2017.
15. Simonyan K., Zisserman A., “Very deep convolutional networks for large-scale image recognition”, *arXiv preprint arXiv:1409.1556*, 2014.
16. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., “Going deeper with convolutions”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1-9, 2015.
17. Voulodimos A., Doulamis N., Doulamis A., Protopapadakis E., “Deep learning for computer vision: A brief review”, *Computational Intelligence and Neuroscience*, vol. 2018, Article ID 7068349, 2018.
18. Schmidhuber J., “Deep learning in neural networks: An overview”, *Neural Networks*, vol. 61, pp. 85-117, 2015.
19. Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., Huang Z., Karpathy A., Khosla A., Bernstein M., Berg A.C., Fei-Fei L., “ImageNet Large Scale Visual Recognition Challenge”, *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211-252, 2015.
20. Ioffe S., Szegedy C., “Batch normalization: Accelerating deep network training by reducing internal covariate shift”, *Proceedings of the 32nd International Conference on Machine Learning (ICML)*, pp. 448-456, 2015.
21. Kingma D.P., Ba J., “Adam: A method for stochastic optimization”, *arXiv preprint arXiv:1412.6980*, 2014.

Додаток А

КОПІЇ ДЕМОНСТРАЦІЙНИХ МАТЕРІАЛІВ

Кафедра Інженерії програмного забезпечення автоматизованих систем

КВАЛІФІКАЦІЙНА РОБОТА

на тему:

«Дослідження використання нейромереж у медицині»

на здобуття освітнього ступеня бакалавра
зі спеціальності 126 Інформаційні системи та технології
освітньо-професійної програми Інформаційні системи та технології

Виконав: Петлицький Б.Р. ІСД-42

Науковий керівник роботи:

Данильченко В.М.

Київ - 2024

1

МЕТА, ОБ'ЄКТ, ТА ПРЕДМЕТ ДОСЛІДЖЕННЯ

Мета роботи: вивчення теоретичних основ нейронних мереж та їх застосування у медицині

Об'єкт дослідження: нейронні мережі як інструмент для діагностики раку грудей

Предмет дослідження: методи та алгоритми використання нейронних мереж для аналізу медичних зображень з метою діагностики раку грудей



2

ДОСЛІДЖЕННЯ РАКУ ГРУДЕЙ

Рак грудей - найпоширеніший рак серед жінок у світі. За даними Всесвітньої організації охорони здоров'я (ВООЗ), у 2020 році було зареєстровано 2,3 мільйона нових випадків раку грудей, що становить 25% всіх випадків раку у жінок.

В Україні, за даними Національного інституту раку, щороку діагностується близько 17 000 випадків раку грудей. Цей тип раку є також однією з найпоширеніших причин смерті серед жінок, щороку забираючи життя близько 7 000 українок.



3

НЕЙРОННІ МЕРЕЖІ У МЕДИЦИНІ



Діагностика:

- Аналіз медичних зображень
- Персоналізована медицина
- Підтримка прийняття рішень лікарями



Лікування:

- Розробка ліків
- Персоналізована терапія




Дослідження:

- Розробка нових медичних технологій
- Відкриття ліків

4

ЗГОРТКОВІ НЕЙРОННІ МЕРЕЖІ

Згортова нейронна мережа (CNN) - це клас глибоких штучних нейронних мереж прямого поширення, які успішно застосовуються для аналізу візуальних зображень з високим ступенем інваріантності до масштабування, переміщення, обертання, ракурсів та інших просторових спотворень. Метою CNN є глибоке дослідження даних за допомогою згорток. Вони ефективно розпізнають об'єкти на зображеннях, а також успішно виконують завдання класифікації.



5


ПРАКТИЧНА РЕАЛІЗАЦІЯ

Реалізація була проведена з використанням мови Python. Для всіх моделей використовували переднавчені ваги, на основі датасету ImageNet



6

ШТУЧНІ НЕЙРОННІ МЕРЕЖІ



Модель перцептрону

7

ОЦІНКА ЯКОСТІ КЛАСИФІКАЦІЇ

У задачі бінарної класифікації, передбачається, що є два класи: позитивний (positive) і негативний (negative). Позитивний клас - це той, який потрібно прогнозувати.


У контексті скринінгових обстежень для раннього виявлення раку результати автоматизованого тесту будуть інтерпретуватися наступним чином: якщо тест негативний, пацієнт буде вважатися здоровим; якщо тест позитивний, пацієнт буде підданий додатковому скринінгу.

Можливі два типи помилок: помилка I типу, яка являє собою хибнопозитивний результат (тест виявив хворобу, але людина здорова – false positive), і помилка II типу, яка являє собою хибнонегативний результат (тест не виявив хворобу, але людина насправді хвора – false positive).

(Також існують терміни: True positive і True negative)

TN	FP
FN	TP

Матриця помилок



8

ОЦІНКА ЯКОСТІ КЛАСИФІКАЦІЇ

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

Формула для обчислення правильності класифікації в контексті машинного навчання

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

Формула для обчислення точності класифікації в контексті машинного навчання

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

Формула для обчислення повноти класифікації в контексті машинного навчання

$$F - \text{MIRA} = 2 \times \frac{\text{ТОЧНІСТЬ} \times \text{ПОВНОТА}}{\text{ТОЧНІСТЬ} + \text{ПОВНОТА}}$$

Обчислення F-міри

$$FPR = \frac{FP}{FP + TN}$$

Обчислення частоти хибнопозитивних результатів



9

ROC-КРИВА

На фото зображено графік кривої ROC (Receiver Operating Characteristic), який використовується для оцінки якості класифікаційних моделей.

На графіку:


- Вісь X представляє "False Positive Rate" (частоту хибно позитивних результатів).

- Вісь Y представляє "True Positive Rate" (частоту вірно позитивних результатів).

- Синя лінія відображає ROC-криву моделі.

- Чорна пунктирна лінія під кутом 45 градусів відповідає випадковому класифікатору (коли модель не має розрізняльної здатності і показники випадково обрані).

Також на графіку вказано значення "area under the curve" (AUC), яке дорівнює 0.79. Значення AUC (площа під кривою) варіюється від 0 до 1 і є мірою якості класифікатора: чим ближче до 1, тим краща модель. У даному випадку AUC дорівнює 0.79, що свідчить про досить хорошу модель.



10

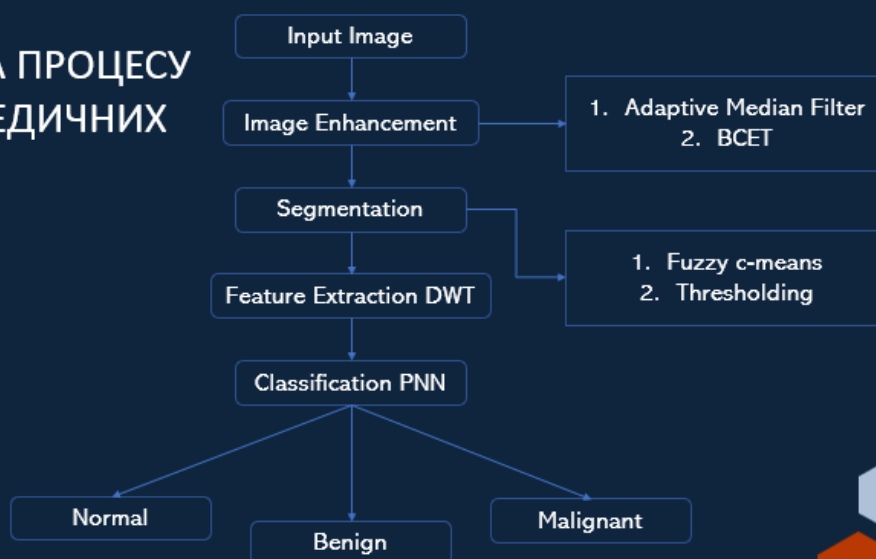
ПРОВЕДЕННЯ ЕКСПЕРЕМЕНТІВ

Для того, щоб ідентифікувати і класифікувати тип пухлини молочної залози кожної пацієнтки, лікарі зазвичай звертаються до зображення і складають звіт про аналіз обстежень пацієнтки. Описаний метод допоможе лікарю діагностувати пухлину молочної залози пацієнтки. Після того, як система буде встановлена, лікар може протестувати її з деякими відомими даними, а потім використати ці дані для створення звіту про дослідження пацієнта.

Якість зображень, отриманих з медичних пристроїв, може впливати на результат обробки (аналізу) при вирішенні діагностичних медичних проблем. У більшості випадків отримані зображення (або набори зображень) мають помітний рівень шуму, зумовлений технологічними особливостями роботи приладів. З огляду на це, автори пропонують наступну процедуру обробки медичних зображень:


11

БЛОК-СХЕМА ПРОЦЕСУ ОБРОБКИ МЕДИЧНИХ ЗОБРАЖЕНЬ



12

РЕЗУЛЬТАТИ




Використання методів інтенсивності, та зіставлення рівнів сірого

Диференціація нормальних і пухлинних клітин також полегшує розрахунок площі уражених ділянок пухлини. Розрахована площа визначається в пікселях. Для визначення площі пухлини використовується дискретне вейвлет-перетворення. В якості матричних (GLCM) методів використовуються методи на основі інтенсивності та методи зіставлення рівнів сірого, як на малюнку. На основі інтенсивності методу можна визначити середнє значення, а також стандартне відхилення.

13

Методи GLCM (матриця суміжності рівнів сірого) допомагають визначити енергію, ентропію, контраст, кореляцію, однорідність і гладкість. Описаний тут метод є більш ефективним для сегментації пухлинної ділянки, ніж інший. У випадку, коли методи, включають деяку непухлинну область в кінцеве сегментоване зображення, наш метод визначає область пухлини, локалізує область пухлини на вихідному вхідному зображенні, і успішно відображає кольоровий результат. Кінцевий результат запропонованого методу показано на рис. 3.14, де у верхньому рядку представлено вихідні зображення (цифрова база даних для скринінгової мамографії (DDSM)).

Другий рядок представляє результат застосування покращеного зображення, описаного в розділі 2 цієї статті. Третій рядок - результат маскування та обробки (кінцеве контурне зображення).



(а) Вхідні зображення; (б) Попередньо оброблені зображення, (в) Результати сегментації та класифікації різних типів пухлин грудей

14

ВИСНОВКИ

У цій роботі було детально досліджено аналіз медичних зображень за допомогою штучних нейронних мереж. Було застосовано різні методи для класифікації зображень та тренування нейронних мереж з використанням різних моделей. Спостерігалось, як ці методи впливають на ROC-криву. Після навчання мережі отримані результати порівнювалися з даними з тестового набору.

Результати показали, що чим довше навчається модель нейронної мережі, тим точнішими стають її прогнози, наближаючись до 100%. Також було виявлено, що ROC-крива не впливає на характеристики моделі. На основі проведеного дослідження можна зробити висновок, що зі збільшенням обсягу вхідних даних кількість помилок, які робить модель, зменшується.

Точне розпізнавання медичних зображень є надзвичайно важливим для своєчасного лікування. У цьому дослідженні пропонується розробити систему для стандартної процедури виявлення раку молочної залози при діагностиці. Цифрова маммографія зараз є стандартним компонентом діагностичного процесу.

Для покращення класифікації в галузі діагностики застосовуються різноманітні методи. Виділення особливостей зображення є ключовим етапом у класифікації мамограм. Ці ознаки виділяються шляхом застосування методів обробки зображень. Площа пухлини повинна бути розрахована за допомогою методу дискретного вейвлет-перетворення (DWT). Нормальні та ракові клітини відображаються окремо, а ентропія, середнє значення, стандартне відхилення, енергія, асиметрія та інші статистичні показники обчислюються на основі зображень у базі даних.

Запропонована нейронна мережа, яка класифікує зображення мамограм на три категорії: нормальні, доброякісні та злоякісні, з точністю понад 90%. Така система може бути корисною як для пацієнта, так і для лікаря.

15



Дякую за увагу!

16