

**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ІМЕНІ ТАРАСА ШЕВЧЕНКА**

Факультет комп'ютерних наук та кібернетики
Кафедра обчислювальної математики

Кваліфікаційна робота
на здобуття ступеня бакалавра
за спеціальністю 113 Прикладна математика
на тему:

**ДОСЛІДЖЕННЯ ЛЕГЕНЕВИХ АНОМАЛІЙ ШЛЯХОМ
ВИКОРИСТАННЯ МАШИННОГО НАВЧАННЯ**

Виконала студентка 4-го курсу

Карпенко Аліса Юріївна


(підпис)


Науковий керівник

доцент Голубєва Катерина Миколаївна


(підпис)

Засвідчую, що в цій роботі немає запозичень
з праць інших авторів без відповідних посилань

Студент


(підпис)

Роботу розглянуто й допущено до захисту
на засіданні кафедри обчислювальної математики

« 29 » травня 2023 р.,

протокол № 8

Завідувач кафедри

Ляшко С. І.



Київ-2023

Реферат

Обсяг роботи: 38 сторінка, 18 джерел посилання, 20 ілюстрацій.

Ключові слова: рак легенів, КТ, машинне навчання, згорткові нейронні мережі, LUNA16, U-Net, N-Net.

Об'єкт дослідження — автоматизоване розпізнавання легеневих аномалій засобами машинного навчання.

Мета роботи — аналіз вже існуючих рішень для розпізнавання легеневих аномалій та практична реалізація деякого методу.

Результати: досліджено алгоритми машинного навчання з та без використання нейронних мереж, проведено історичний огляд розвитку автоматичного розпізнавання легеневих аномалій.

Організація роботи проведена таким чином: список позначень, вступ, який містить основні причини проведення дослідження та короткий огляд застосовуваних технологій.

Теоретична частина складається з чотирьох розділів, в яких розглядаються відомості про КТ-діагностику, алгоритми, що не використовують нейронні мережі, огляд датасету та детальний опис трьох нейронних мереж для біомедичних зображень, кожен з яких можна використовувати для задачі пошуку легеневих аномалій.

Зміст

Вступ.....	4
Розділ 1. Принципи діагностики раку за допомогою КТ.....	6
1.1. Принципи роботи КТ.....	6
1.2. Ознаки наявності легеневого захворювання на КТ.....	8
Розділ 2. Загальний огляд пов'язаних робіт.....	10
2.1. Алгоритми виявлення легеневих аномалій.....	10
2.1.1. Алгоритм ISICAD.....	10
2.1.2. Алгоритм SubsolidCAD.....	11
2.1.3. Алгоритм LargeCAD.....	13
Розділ 3. Загальний огляд датасету LIDC/IDRI.....	13
Розділ 4. Нейромережевий підхід для розпізнавання зображень.....	15
4.1. Загальний огляд згорткових нейронних мереж.....	16
4.1.1. Анкори.....	18
4.2. Проблеми навчання нейронних мереж.....	19
4.3. U-Net.....	20
4.3.1. Архітектура нейромережі.....	21
4.4. 3D CNN для розпізнавання туберкульозу.....	23
4.4.1. Препроцесінг даних.....	23
4.4.2. Архітектура мережі.....	25
4.5. 3D CNN для розпізнавання раку легенів N-Net.....	27
4.5.1. Препроцесінг даних.....	27
4.5.2. Перетворення даних.....	30
4.5.3. Архітектура нейронної мережі.....	31
4.5.4. Подальша класифікація.....	34
Розділ 5. Практична частина.....	36
5.1. Препроцесінг даних.....	36
5.2. Аналіз даних.....	37
5.3. Доповнення даних.....	39
5.4. Тренування та тестування.....	40
Висновки.....	41
Список використаних джерел.....	42

Вступ

Оцінка стану проблеми. Рак легенів є першою за величиною причиною смертності від раку серед чоловіків та другою серед жінок. Світовий рівень смертності складає 18.0 на 100 000 населення за даними World Cancer Research Fund International на 2020 рік.

Найбільший ризик мають країни, що розвиваються, на кшталт Сербії, Французької Полінезії, Боснії та Герцоговини тощо, але також ця хвороба не оминає і такі європейські країни як Франція, Данія, Нідерланди та інші.

Найвищий рівень смертності в Європі спостерігається в Угорщині — 42.4 на 100 000 населення при рівні захворюваності в 50.2 за даними World Cancer Research Fund International на 2020 рік.

Також в США за даними від Centers of Disease Control and Prevention на 2019 смертність в середньому становила 33.5 на 100 000 населення, а в деяких штатах таких як Міссурі, Кентуккі чи Огайо досягала рівня 60.0 та вище.

На даний момент для виявлення даного захворювання застосовують переважно діагностику за допомогою КТ — комп'ютерної томографії — результати якої досліджує лікар-радіолог на наявність вузлів — утворень в легенях, які можуть бути першою стадією раку.

На жаль, більшість пацієнтів, які мають рак легенів, звертаються за допомогою занадто пізно.

Актуальність. Оскільки рак легенів є майже основною причиною смертності від раку в усьому світі, то пропонують запровадити масовий скринінг осіб з високим ризиком раку легенів.

При КТ-скринінгу раку легенів необхідно проаналізувати кілька мільйонів КТ-знімків, що є величезним навантаженням для радіологів — лікарів, що здійснюють діагностику раку та інших захворювань за

допомогою візуальних матеріалів, отриманих при проходженні іонізуючого випромінювання крізь тіло людини, на кшталт КТ чи рентгену.

Тому існує великий інтерес до розробки комп'ютерних алгоритмів для оптимізації скринінгу.

Сучасний рівень розвитку машинного навчання дозволяє реалізувати достатньо точну систему, яка дозволяє провести масовий скринінг з мінімальним людським втручанням, що значно полегшує та прискорює даний процес.

Мета і завдання роботи. Метою даної кваліфікаційної роботи є аналіз теперішнього стану розв'язку проблеми створення програмного засобу виявлення легеневих аномалій для масового скринінгу, аналіз застосованих технологій та практична реалізація такого програмного засобу.

Для виконання поставленої мети необхідно виконати такі кроки:

- Дослідити причини, патогенез та методи діагностики раку легенів;
- Провести аналіз робіт, які вивчали питання автоматичної діагностики раку легенів за допомогою методів машинного навчання;
- Реалізувати модель машинного навчання, яка з деякою точністю буде визначати наявність злоякісного утворення в легенях.

Об'єкт, методи й засоби розроблення. Об'єктом даної роботи є датасет LIDC/IDRI, зібраний в 2016 році лікарями з США. Це датасет, який містить декілька тисяч знімків КТ легенів. На ньому буде реалізований ручний попередній аналіз даних та модель машинного навчання за допомогою мови програмування Python та її бібліотек.

Процес розробки відповідатиме стандарту розробки в сфері Data Science під назвою OSEMN, що означає: Obtain, Scrub, Explore, Model, Interpret, тобто зібрати дані, очистити, дослідити, змодельовати та оцінити результати. Даний процес є циклічним, оскільки при розробці рішень

машинного навчання необхідно пройти декілька ітерацій OSEMN для досягнення прийняттого результату.

Можливі сфери застосування. Системи автоматичного скринінгу полегшують роботу лікарів, знижуючи навантаження.

Це дозволяє зробити охоплення скринінгом більш масовим, тобто збільшити шанси людей, які мають рак, дізнатися про захворювання на ранніх стадіях та отримати належне лікування.

Системи машинного навчання можуть інтегруватися в веб- чи десктоп-застосунки, що дає можливість працювати з ними з будь-якого куточку країни.

Взаємозв'язок з іншими роботами. Дана робота взаємопов'язана з дослідженнями різноманітних наукових установ, розробкою методів автоматичної діагностики в рамках онлайн-змагання з машинного навчання LUNA16 та з дослідженнями лікарів-радіологів в сфері діагностики раку легенів з використанням КТ-знімків.

Розділ 1. Принципи діагностики раку за допомогою КТ


1.1. Принципи роботи КТ

Загальний процес КТ-сканування відбувається таким чином: пацієнта в положенні лежачи просвічують тонким рентгенівським променем, який в площині, що перпендикулярна осі тіла, описує коло навколо пацієнта і таким чином отримується зображення тонкого шару людського тіла.

Загальна структура апарату КТ складається з:

1. Гентрі: джерело рентгенівських променів, детектори сигналів, система, яка забезпечує переміщення елементів апарату
2. Система перетворення інформації, що реєструється детекторами, на електричні сигнали

3. Обчислювальний апарат — комп'ютер
4. Систему запису результатів на носії
5. Стіл для розміщення пацієнта



Мал. 1: загальна будова апарату КТ

Таким чином, КТ — це система, що перетворює рентгенівські промені на електричні сигнали, які обробляються комп'ютером, утворюючи картинку, сприйнятну людському оку.

Розглянемо загальний алгоритм отримання зображення КТ

1. Область сканування просвічується тонким пучком рентгенівських променів, які є перпендикулярними осі тіла;
2. На протилежному боці реєструється випромінювання за допомогою встановлених детекторів;
3. Випромінювання перетворюється на електричні сигнали;
4. Комп'ютер обробляє сигнали і перетворює їх на 3-вимірне зображення

Зображення КТ має сенс за рахунок різної пропускнуої спроможності тканин. Тобто кістки пропускають менше випромінювання, м'які тканини — більше, що дає зображення з різними інтенсивностями, завдяки яким людина бачить обриси кісток, внутрішніх органів тощо.

Перевагами КТ є:

1. Швидке отримання результатів, можливість використання у випадках травм, що потребують негайної діагностики
2. Отримання тривимірного скану людського тіла
3. Можливість отримання зрізу до 1мм

Серед мінусів:

1. Високий рівень опромінення
2. Неможливість проведення КТ для вагітних

1.2. Ознаки наявності легеневого захворювання на КТ

Основним методом визначення раку легенів є рентгенологічне дослідження, яке дозволяє визначити захворювання на стадії, де ще можливе лікування, у 80% випадків.

На КТ пухлини дають суттєвий відгук, коли досягають розміру 3-4 см, до цього моменту їх вплив на зображення незначний. Для отримання більш точних результатів використовують КТ з контрастом або тонкозрізове КТ.

В Україні в основному використовується КТ з кроком в 10 мм, яке здатне виявляти аномалії розміром більше сантиметра. Але в дослідженні, за яким збирався датасет LIDC/IDRI використовувалося КТ з кроком в 3 мм чи менше, що дало можливість виявляти навіть найменші утворення.


КТ легенів складається з багатьох шарів, наприклад, в датасеті LIDC/IDRI одне КТ має 121 шар.

Серед цих шарів лікарі виділяють 7 найбільш інформативних:

1. Верхівковий
2. Грудинно-ключичних зчленувань
3. Дуги аорти
4. Біфуркації трахеї
5. Легенові артерії

6. Основи серця

7. Діафрагмальний



Мал. 2: приклад КТ органів грудної клітини, в яких не виявлено патологій

Основною ознакою наявності онкологічних процесів в легенях є синдром круглої тіні. Він виявляється як напівкругла тінь діаметром більше 1 см. Для ствердження, що виявлена тінь відображає патологію, досліджують положення тіні, співвідношення з прилеглими органами, кількість тіней, форму, розміру, інтенсивність тощо.

Поодинокі тіні спостерігаються у випадках абсцесу, туберкульозу, кісти, пухлини. Множинні невеликі утворення — метастази злоякісних пухлин в легенях.

Розміри залежать від стадії розвитку пухлини, але тіні великих розмірів можуть давати також ехінококові кісти, плеврити, доброякісні пухлини та абсцеси.

Розділ 2. Загальний огляд пов'язаних робіт

Задачу виявлення легеневих аномалій можна розглядати з двох позицій.

1. Виявлення легеневих аномалій: розпізнавання засобами машинного навчання елементів на знімку КТ, що схожі на вузли, і отримання карти цих вузлів.
2. False positive reduction (зменшення хибнопозитивних результатів) — власне завдання класифікації — підозрілий вузол чи звичайний рельєф легень — зображень на основі деякого набору ознак, що були отримані при виявленні легеневих аномалій, тобто створення класифікатора злоякісності пухлин.

У процесі дослідження робіт пов'язаних з темою виявлення легеневих аномалій було розглянуто декілька алгоритмів, створених для виявлення легеневих аномалій.

2.1. Алгоритми виявлення легеневих аномалій

2.1.1. Алгоритм ISICAD

Загальний алгоритм виявлення кандидатів на аномалії був розроблений Мерфі та іншими в 2009 році.

Спочатку зображення зменшується з 512×512 до 256×256 , а кількість зрізів зменшується до ізотропної роздільної здатності. Тобто таким чином, щоб для кожної точки в знімку її властивості були однакові в будь-якому напрямку. Тобто щоб відстані за усіма осями були рівні або прирівняти товщину зрізу до розміру пікселю.

Оскільки маємо справу з тривимірними даними, то якщо в двовимірному просторі кожну точку на зображенні називали піксель, зараз вона називатиметься воксель.

Після перетворення зображення для кожного вокселя обчислюється індекс форми (SI) та кривизна (CV) обчислюються для кожного вокселя в об'ємі легені наступним чином:

$$SI = \frac{2}{\pi} \cdot \arctg\left(\frac{k_1+k_2}{k_1-k_2}\right)$$

$$CV = \sqrt{k_1^2 + k_2^2}$$

де k_1 та k_2 - головні компоненти, обчислені за похідними першого та другого порядку від зображення з гаусовим розмиттям масштабу $\sigma = 1$ на воксель.

Після обчислення SI та CV, застосовуємо порогове значення цих величин для отримання початкових точок для кандидатів на аномалії. Якщо точка пройшла обидва порогові значення вважаємо її значущою. Ці точки є вокселями, які можуть лежати на зовнішній поверхні легеневого вузла.

Початкові точки розширюються з використанням ширших порогових значень для формування кластерів вокселів.

Для зменшення кількості кластерів, кластери розміром в 3 вокселя об'єднуються між собою. Далі підраховується центр маси кластера і вважається підозрілим на аномалію.

Алгоритм було розроблено з використанням набору даних з великого європейського дослідження.

2.1.2. Алгоритм SubsolidCAD

Даний алгоритм був розроблений для виявлення subsolid (напів щільних) вузлів, які зустрічаються рідше, але з більшою ймовірністю можуть бути раковими. Вони мають меншу інтенсивність, ніж щільні вузли, але їхня злякисність вища.

SubsolidCAD алгоритм виявлення аномалій застосовує маску подвійної порогової щільності.

За основу покладається індекс HU — Hounsfield unit або шкала одиниць Хаунсфілда — що визначає щільність тканини для рентгенівського випромінювання. Він обраховується за такою формулою

$$HU = \frac{\mu_x - \mu_{water}}{\mu_{water} - \mu_{air}} \times 100$$

Де μ_{water} — це лінійний коефіцієнт ослаблення випромінювання для води, а μ_{air} — це лінійний коефіцієнт ослаблення повітря.

За шкалою Хаунсфілда значення для води приймається за 0, а для повітря — -1000. Якщо тканина більш щільна, тобто затримує більше випромінювання, то її HU відповідно більша.

Наведемо кілька значень Хаунсфілда для різних тканин: жир — -120, м'які тканини — 40, кістки — більше 400.

Для побудови маски використовуються значення HU, які зазвичай спостерігаються в субсолідних вузлах: в діапазоні від -750 HU до -300 HU. Оскільки деякі аномалії можуть виникати на межі легень, судин і дихальних шляхів, судин і дихальних шляхів, використовується деяка межа (зазвичай в 3 вокселі) для видалення цих структур з даного аналізу. Далі виконується аналіз зв'язаних за маскою компонент.

Компоненти з об'ємом менше 34 мм³ відкидаються зі списку підозрілих на аномалію, оскільки субсолідні вузли діаметром менше ніж 5 мм не вважаються небезпечними.

Алгоритм був розроблений з використанням набору даних з великого європейського дослідження раку легенів.

2.1.3. Алгоритм LargeCAD

Алгоритм виявляє великі щільні вузли. Такі вузли (≥ 10 мм) мають значення індексу поверхні/форми або конкретний інтервал інтенсивності. Тобто це вузли, які мають певну форму, певний коефіцієнт ексцентриситету та певну інтенсивність в одиницях Хаунсфілда.

Застосовується поріг інтенсивності -300 HU (зазвичай відповідає щільним вузлам) в поєднанні з кількома операціями, що дозволяють виявити деякі морфологічні ознаки.

Після цього всі з'єднані вокселі групуються за допомогою аналізу з'єднаних компонентів; групи з діаметром поза діапазоном [8, 40] мм відкидаються.

Алгоритм був розроблений за допомогою набору даних, використаних у LUNA16.

Розділ 3. Загальний огляд датасету LIDC/IDRI

Набір даних було зібрано з найбільшої загальнодоступної бази даних легеневих вузлів. База даних LIDC-IDRI містить загалом 1018 КТ-сканів. КТ-зображення пов'язані з XML-файлами з анотаціями від чотирьох досвідчених радіологів.

База даних дуже неоднорідна: вона складається з КТ-знімків з різними дозами опромінення, зібраних у семи різних наукових установах. Також, дані знімки отримувались на різних апаратах КТ з різними параметрами.

Згідно рекомендацій для точної діагностики використовуються тонкозрізові КТ, з товщиною зрізу до 3 мм, тому при зборі інформації було видалено усі знімки з більшою товщиною зрізу.


Крім того, також були виключені скани з непослідовною відстанню між зрізами або з відсутніми зрізами. В результаті було отримано остаточний список, який складався з 888 знімків.

Скани представлені у форматі Metaimage (.mhd).

Кожен знімок з LIDC-IDRI було анотовано радіологами в процесі двофазного аналізу.

На початковій фазі сліпого аналізу чотири радіологи незалежно один від одного коментували скани і позначали всі підозрілі утворення як:

1. “Вузол > 3 мм” визначається як будь-яке ураження, що вважається як вузол з найбільшим діаметром у який-небудь з площин в діапазоні 3-30 мм, незалежно від його гістологічного малюнку: тобто відносяться і злоякісні утворення, і доброякісні.
2. “Вузол 3 мм” визначається як будь-яке ураження, яке вважається як вузол з найбільшим діаметром у будь-якій площині менше 3 мм, який не є явно доброякісним.
3. “Не вузлове ≥ 3 мм” — це будь-яке інше легеневе ураження, наприклад, туберкульозний пухирець, з найбільшим діаметром у будь-якій площині ≥ 3 мм, яке не має ознак, що відповідають ознакам вузола.



Мал. 3: приклади легневих вузлів різних розмірів

На наступній фазі аналізу знімків, анонімні результати всіх інших радіологів були показані кожному. Потім кожен лікар незалежно переглянув свої оцінки. Досягнення консенсусу не вимагалось.

На 888 знімках загалом було зроблено 36 378 анотацій. Було розглянуто лише ті анотації, які були віднесені до категорії вузли ≥ 3 мм як дійсно підозрілі ураження, оскільки вузли < 3 мм і утворення, які не є вузлами не вважаються релевантними для протоколів скринінгу раку легень. Вузли можуть бути анотовані кількома радіологами; анотації від різних дослідників, які були розташовані ближче, ніж сума їхніх радіусів, об'єднувалися. У цьому випадку положення і діаметри цих об'єднаних анотацій усереднювалися.

В результаті було отримано набір з 2290, 1602, 1186 та 777 вузлів анотованих від 1 до 4 радіологів.

Для даного датасету було розглянуто 1186 вузлів, анотованих більшістю радіологів (щонайменше 3 з 4 радіологів), як дійсно підозрілі. Це ті ураження, які алгоритми повинні виявляти.

Інші відмітки радіологів: 1104 вузли, анотовані менш ніж 3 з 4 радіологів, 11 509 анотацій "вузол < 3 мм" і 19 004 анотації "без вузлів" вважалися "нерелевантними знахідками", і позначки на цих ділянках не враховувалися.

Нерелевантні результати були виключені з оцінки, оскільки вони являють собою легеневі аномалії, які можуть бути важливими для іншого клінічного діагнозу.

Таким чином, якщо алгоритм на такому вузолу визначить його підозрілим, то це не є справжнім false-positive (хибнопозитивним) результатом. Тобто було досягнуто розуміння щодо того, що саме слід вважати false-positive анотацією.

Розділ 4. Нейромережевий підхід для розпізнавання зображень

З розвитком комп'ютерних технологій для розпізнавання зображень все частіше почали використовувати нейромережі.

Нейромережа — це математична модель, яка імітує роботу людського мозку. Тобто вона складається з нейронів, які обробляють інформацію та зв'язків між нейронами, які цю інформацію передають.

Нейромережі не є засобами, що програмуються, а є засобами, що навчаються, тобто для отримання передбачення, нейронна мережа не використовує попередньо задані правила, які написані програмістом, а в процесі навчання вивчає дані і на основі їх виводить свої власні правила, які максимально відповідають даним.

У випадку, якщо дані змінюються, після перенавчання нейронна мережа створює нові правила, вже під нові дані.

Наразі є багато архітектур нейронних мереж, які використовуються для розв'язку різноманітних задач. Для найпростіших з них використовуються повнозв'язні нейронні мережі, для більш складних — згорткові мережі, рекурентні тощо.


4.1. Загальний огляд згорткових нейронних мереж

Для задач розпізнавання зображень використовуються зазвичай згорткові нейронні мережі або convolutional neural networks — CNN. Основним принципом роботи згорткових нейронних мереж є використання концепції згортки, яка є математичною операцією, що поєднує дві функції для отримання третьої функції. В контексті нейромереж згортка використовується для вилучення ознак з вхідних даних.

Загальна архітектура згорткової нейронної мережі складається з таких елементів:

1. Декілька згорткових шарів: кожен шар має деякий фільтр або ядро, за допомогою якого виявляються закономірності в даних

2. Pooling layer (або шар об'єднання) — це шар, який зазвичай йде після згорткових шарів, щоб зменшити розмірність результату роботи згорткового шару із збереженням основної інформації
3. До кожного шару нейронної мережі застосовується функція активації, яка необхідна, щоб внести до мережі нелінійність та покращити її обчислювальні якості
4. Також до архітектури CNN входять так звані повнозв'язні шари — це шари, де кожен нейрон пов'язаний з нейронами сусідніх шарів. Ці шари використовуються для побудови прогнозів на основі ознак, які було отримано зі згорткового та pooling шарів.



Мал. 4: загальний вигляд згорткової нейронної мережі

Для навчання згорткових нейронних мереж, як і для навчання повнозв'язних мереж, можна застосувати метод обратного розповсюдження помилки (back propagation) за допомогою стохастичного градієнтного спуску.

4.1.1. Анкори

Для збільшення передбачувальної здатності згорткової мережі використовуються так звані анкори.

Анкор в згорткових нейронних мережах використовується для обробки об'єктів різних розмірів в зображеннях — це фіксовані прямокутники або квадрати, розташовані на різних місцях зображення.

Використовуються у задачах object detection (об'єктного виявлення), де необхідно знайти та класифікувати об'єкти в зображеннях. Анкори визначають можливі положення об'єктів в зображенні і використовуються для створення пропозицій, які потім підлягають подальшому аналізу.

Під час проходження зображення крізь згорткову нейронну мережу, анкори застосовуються до різних областей зображення, і для кожного визначається ймовірність присутності об'єкта та виконуються корекції щодо його ймовірного розташування. За допомогою анкорів модель може виявляти об'єкти різних розмірів та форм.

Також вони допомагають покращити точність object detection, адаптуючись до різних розмірів об'єктів у зображенні і враховуючи їх контекст. Вони є важливою складовою процесу обробки зображень у згорткових нейронних мережах, дозволяючи моделі ефективно працювати з об'єктами різних форм та розмірів.

У виявленні об'єктів метою є ідентифікація та локалізація об'єктів на зображенні. Анкори слугують як посилання на bounding boxes (обмежувальні рамки), які розміщуються на різних позиціях і масштабах по всьому зображенні і показують розташування об'єкта. Ці анкори виступають як потенційні кандидати для співставлення та прогнозування розташування об'єктів.

Кількість анкорів зазвичай відповідає кількості різних масштабів, що розглядаються для завдання виявлення.

За допомогою різних розмірів анкорів та масштабування модель стає здатною виявляти об'єкти різних масштабів та форм на вхідному зображенні. Кількість анкорів впливає на гнучкість та деталізацію прогнозів моделі.

Однак, якщо використовувати занадто багато анкорів, то модель втрачає в швидкості навчання, тому необхідно відшукати компроміс між точністю передбачень та обчислювальною складністю

4.2. Проблеми навчання нейронних мереж

Навчання згорткової нейронної мережі є ресурсомістким завданням, яке вимагає:

1. Велику кількість даних. Дані — найбільш дорогий ресурс, оскільки їх збір пов'язаний з багатьма юридичними, етичними та технічними викликами.
2. Ресурси комп'ютера. Навчання нейронної мережі з точки зору математики — це множення матриць та їх додавання, такі операції є місткими і потребують потужних процесорів чи відеокарт.
3. Час. Складні нейронні моделі навіть на найсучасніших відеокартах навчаються довго.
4. Архітектура. Побудова архітектури, яка дозволить отримати якісні результати та не буде використовувати багато ресурсів — це питання, яке розв'язується роками.

Отже, для багатьох завдань можна використовувати надбання минулих поколінь і працювати з вже відомими архітектурами та їх модифікаціями, а також використовувати переднавчені нейронні мережі.

Переднавчена нейронна мережа — це нейронна мережа, яка була попередньо навчена на деякому наборі даних і користувачеві поставляється з вже підібраними вагами.

Користувач може завантажити таку нейронну мережу та донавчити її на своїх даних. Такий підхід значно полегшує та прискорює процес отримання рішення поставленої задачі.

Отже, для даної задачі знаходження легневих аномалій можна використати деяку з вже наявних архітектур нейронних мереж. Архітектур нейромереж, які працюють саме з легенями небагато, але в рамках деяких досліджень були створені такі мережі як LungNet та інші.

Розглянемо надалі декілька архітектур нейромереж, які здатні оброблювати 3D зображення, а також ті, які були призначені для роботи з 3D медичними матеріалами.

4.3. U-Net

U-Net є популярною архітектурою нейромережі, яка використовується для сегментації зображень. Вона була розроблена в 2015 році і отримала назву U-Net через свою схожість з літерою "U", якщо графічно зобразити її структуру. Ця архітектура досить гнучка та ефективна, особливо в сферах, де необхідна детальна сегментація об'єктів таких як медичні та біологічні зображення.

Архітектуру U-Net розробив Ольф Цеєгерт, дослідник з Інституту мікрохірургії та нейроінженерії Шаріта (Charité - Universitätsmedizin Berlin) в Німеччині. У роботі "U-Net: Convolutional Networks for Biomedical Image Segmentation", опублікованій в журналі "MICCAI" (Medical Image Computing and Computer Assisted Intervention) він представив архітектуру U-Net і продемонстрував її ефективність для задач сегментації біомедичних зображень.

4.3.1. Архітектура нейромережі

Архітектура U-Net складається з двох головних частин: енкодера та декодера. Енкодер використовується для поступового зменшення розміру зображення та його зменшеного представлення на вищому абстрактному рівні. Декодер виконує обернену операцію, збільшуючи розмір представлення та відновлюючи деталі об'єктів.

Основна структура U-Net складається з енкодер-декодер зв'язку зі з'єднувальними шляхами (skip connection). Кожен з'єднувальний шлях відображає відповідну шкалу (scale) в енкодері до відповідної шкали в декодері. Це дозволяє передавати інформацію про контекст з енкодера до декодера, допомагаючи знаходити відповідність об'єктів на різних масштабах.

Шкала — це послідовність, що кодує рівні абстракції зображення, які відображаються за допомогою блоків енкодера чи декодера.

У енкодері U-Net використовується пірамідальна структура, де зображення поступово зменшується за розміром і збільшується за рівнем рівнем абстракції.

Кожен наступний блок енкодера має подвійну кількість фільтрів порівняно з попереднім блоком, що дозволяє розширювати список ознак, які можна витягнути з зображення. За рахунок цього процесу зменшення розміру та збільшення абстракції, шкала енкодера відображає різні рівні інформації про зображення, починаючи від деталей та локальних особливостей до більш глобальних зразків та контексту.

Шкали енкодера використовуються для передачі інформації до відповідних шкал декодера через з'єднувальні шляхи. Це дозволяє декодеру отримати контекстуальну інформацію з енкодера та використовувати її для відновлення деталей та точної сегментації об'єктів на вищому рівні абстракції.

Енкодер складається з послідовних блоків, кожен з яких містить два згорткових шари (convolutional layer) із застосуванням функції активації ReLU та шаром згортки (max pooling) для зменшення розмірності. Після кожного згорткового шару, виконується операція батч-нормалізації (batch normalization), що допомагає прискорити збіжність та стабілізувати процес навчання.




Рис 5: загальна архітектура мережі U-Net

Декодер має аналогічну структуру, але замість оператора згортки використовується оператор транспонованої згортки (transpose convolution), який здійснює збільшення розміру зображення. Кожен блок декодера також містить два згорткових шари, але з використанням з'єднувальних шляхів, що допомагають з'єднати інформацію про зображення з енкодера та декодера.

У практичній реалізації, шляхи з'єднання в U-Net здійснюються шляхом конкатенації відповідних шарів з енкодера та декодера. Наприклад,

шар з найнижчою роздільною здатністю у декодері з'єднується з відповідним шаром у енкодері, що має вдвічі більше фільтрів.

На останньому етапі, після блоків декодера, виконується згортковий шар з одним фільтром, що відповідає кількості класів, на які потрібно сегментувати зображення. Цей шар використовує функцію активації softmax, що генерує ймовірності належності кожного пікселя до різних класів.

U-Net є ефективною архітектурою для сегментації зображень, оскільки вона дозволяє виявляти як глобальні, так і локальні особливості на зображенні завдяки з'єднувальним шляхам.

4.4. 3D CNN для розпізнавання туберкульозу

4.4.1. Препроцесінг даних

Для того, щоб отримана мережа могла передбачати дані правильним чином необхідно провести препроцесінг.

3D дані можна уявити собі як послідовність 2D картинок — слайсів зображення. Зазвичай для роботи з такими даними використовуються алгоритми, які випадковим чином вибирають підпослідовність слайсів.


Це робиться для того, щоб стандартизувати дані перед надходження до нейронної мережі, оскільки якщо розмір за двома осями зазвичай стандартизований, то кількість слайсів вельми мінлива.

Алгоритми, які випадково вибирають певну кількість слайсів, на кшталт Subset Slice Selection (SSS) або обирають за деяким правилом як Even Slice Selection (ESS) мають недоліки, що не дозволяють належним чином відобразити об'ємну картинку для представлення нейронною мережею.

Розглянемо алгоритм ESS, як більш просунутий. Його ідея полягає в тому, що береться бажана кількість слайсів — N та наявна — D . Будується крок $F = \frac{D}{N}$ і далі слайси вибираються з кроком F .

Такий алгоритм не дозволяє використати усі наявні слайси і не відображає усі просторові закономірності, які є в даних.

Алгоритм SSS — це алгоритм який вибирає N слайсів випадковим чином. На рисунку нижче можна побачити, що це може призводити до занадто великого стрибка: від діафрагми майже до середини легенів (відмічено червоним). Звідси можна зробити висновок, що модель не побачить інформації в цьому проміжку, а також побачить більш щільно інформацію про верхню частину легень. Тобто за умовною віссю z отримуємо спотворення простору.



Мал. 6: різниця між вибором семплів за допомогою методів SSS та SIZ

Для запобігання даним проблемам можна застосувати більш досконалий алгоритм, який дозволяє отримати більш повну інформацію. Розглянемо алгоритм Spline Interpolation Zoom — SIZ.

Тут також використовується деякий параметр — $DF = \frac{1}{D/N}$, де D — поточна глибина зображення, а N — бажана. Далі використовується

бікубічна інтерполяція з параметром DF і отримуються на виході дані бажаної глибини.

Цей метод дає кращі результати, оскільки бажана кількість слайсів та відстані між ними досягаються за допомогою інтерполяції — отриманих нових значень на основі старих.

Що дозволяє не спотворювати відстані між слайсами та використовувати всю інформацію з початкових даних.

4.4.2. Архітектура мережі

Дана нейронна мережа була розроблена для розпізнавання наявності туберкульозу в легенях на основі КТ-знімків.

Її особливість в тому, що вона розглядає КТ-знімок не як послідовність 2D картинок, а як тривимірний об'єкт, хоча і працює з представленням знімку як послідовністю 2D картинок.

Загальна архітектура мережі складається з двох блоків: виділення ознак та власне прогнозування.

Розглянемо яким чином побудований блок виділення ознак

1. 4 згорткових шари, два з яких містять по 64 фільтри, а ще два по 128 та 256, розміри ядра яких $3 \times 3 \times 3$.
2. Після кожного згорткового шару розташований шар max pooling, який має крок 2 та функцією активації якого є ReLU.
3. Після цього слідує шар під назвою batch normalization, який прискорює роботу нейронної мережі.

Після отримання ознак, що описують картинку, йде друга частина нейронної мережі, яка на основі отриманих ознак робить прогнози. У даному випадку це буде бінарна класифікація.

Розглянемо структуру даного блоку.

1. Перший шар приймає на вхід отримані ознаки і передає їх на вхід до наступного шару

2. Другий шар складається з 512 нейронів і робить власне передбачення, для задачі бінарної класифікації використовується функція активації softmax, яка перетворює надані на вхід дані у ймовірності. В даному випадку у ймовірності належності до одного з двох можливих класів.
3. Для запобігання перенавчанню та прискорення роботи нейронної мережі використовується також dropout з рівнем викиду в 60% — даний рівень був отриманий емпірично.




Fig. 2: Our proposed 17-layer 3D convolutional neural network architecture which consist of several modules of 3D conv, maxpool and batch normalization layers.

Мал. 7: структура нейронної мережі для розпізнавання туберкульозу

Дана модель є простою порівняно зі звичайною моделлю для розпізнавання об'єктів, хоча має має 10 658 498 параметрів, для даної області — це невелика цифра. Розробники намагалися уникнути over parameterization problem — тобто проблему роботи з моделлю, в якій більше параметрів, ніж треба для вирішення даної задачі, що призводить до уповільнення процесу навчання та власне перенавчання нейронної мережі.

4.5. 3D CNN для розпізнавання раку легенів N-Net

У 2017 році, інтернет-ресурс Kaggle проводив змагання з розпізнавання раку легенів на початкових стадіях. Розглянемо підхід команди, яка посіла перше місце.

Їх метод складається з трьох основних частин: препроцесінг даних, генерація кандидатів та бінарна класифікація. Для генерації та класифікації застосовуються дві різні нейронні мережі, що відрізняє дане рішення від минулої нейромережі.

4.5.1. Препроцесінг даних

Препроцесінг даних складається з кількох етапів, на кожному з яких формуються деякі ознаки, які полегшуватимуть навчання для моделі.

Для початку усі дані було перетворено на одиниці Хаунсфілда — вищезгадані одиниці проникності випроміненням тканин людини.

Після цього нульового етапу було проведено ще три етапи препроцесінгу.

Утворення маски. Оскільки всередині КТ-знімку не тільки легені, а й оточуючі тканини: кістки, діафрагма, серце тощо, то деякі з них можуть мати сферичну форму: наприклад, стравохід або деякі частини серця. Щоб запобігти неправильному їх розпізнаванню необхідно створити так звану маску легенів, яка б ігнорувала усі тканини, окрім легеневих.

Для цього кожне 3D зображення розбивається на 2D слайси, кожен яких пропускається крізь Гаусовський фільтр і далі бінаризується з порогом -600 — число Хаунсфілда, що описує більшу частину легеневих тканин.

Усі компоненти, які мали площу меншу за 30 міліметрів квадратних, або їхній ексцентриситет був більший за 0.99 (тобто ті об'єкти, що не мали форми наближеної до кола) були видалені.

Після цього усі елементи були об'єднані в єдину тривимірну матрицю і видалені елементи, що торкалися границь матриці чи мали об'єм менший за 0.68 L або більший за 7.5 L.

Після таких дій залишаються лише елементи, які містяться в легенях. Але для того, щоб уникнути деяких елементів, які мають схожу структуру, але не належать до легень, необхідно провести ще один крок препроцесінгу.

Для кожного зрізу кожного елементу розраховується дистанція до центру зображення, оскільки легені знаходяться ближче до центру, а аномальні елементи ближче до країв. Також обчислюється площа кожного зрізу кожного елементу.

Після цього вибираються зрізи, площа яких більша за 6000 мм^2 і розраховується середнє по дистанціям до центру в цьому зрізі. Якщо така дистанція більша за 62 мм, то елемент видаляється.

Ті елементи, що залишилися об'єднуються та утворюють маску.

Виділення опуклої оболонки. Деякі вузли знаходяться на границі легенів та іншої тканини. Маска, що була отримана на минулому кроці, не враховує їх.

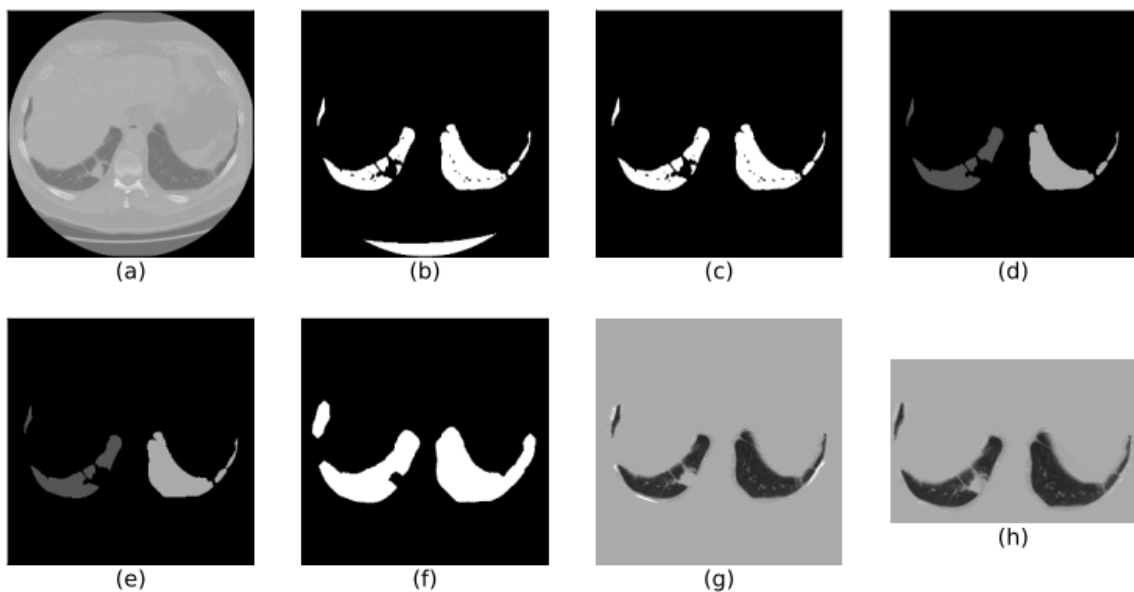
Для того, щоб ці вузли потрапили в розгляд, необхідно взяти опуклу оболонку даної маски. Але, оскільки при побудові звичайної опуклої оболонки будуть враховуватись тканини, що не мають жодного відношення до легенів: серце, хребет, то було прийнято рішення розбити легені на дві частини: праву та ліву легені. (Мал. 8 е)

Для кожної легені маска рахується окремо і для кожного зрізу будується його опукла оболонка. Після цього вона розширюється на 10 вокселів, щоб зберегти деяку інформацію про навколишнє середовище.

Результуюча оболонка будується об'єднанням опуклих оболонок кожної з легень. (Мал. 8 f)

Однак, деякі частини легенів мають неопуклу форму (показані на малюнку нижче), тому для них опукла оболонка матиме занадто багато сторонніх тканин. Тому для запобігання цьому якщо опукла оболонка для

деякого зрізу є більшою за площею більш ніж в 1.5 рази за площу вихідної маски, то зберігається вихідна маска. Опукла оболонка не застосовується.




Мал. 8: етапи препроцесінгу на прикладі нижніх зрізів КТ легенів

Нормалізація інтенсивності зображення. Оскільки нейронна мережа працює із зображеннями, інтенсивності яких нормалізовані в діапазоні від 0 до 255, то необхідно перетворити зображення з діапазону чисел Хаунсфілда — від -1200 до 600 — до звичайного діапазону.

Для цього лінійно перетворюємо початкові дані до діапазону [0, 255]. Після цього вони перемножуються з отриманою маскою і усі вокселі, які не належать до легенів заповнюються значенням 170 — середнє значення. Для уникнення помилкової класифікації кісток як вузлів, оскільки кістки є тканиною, що має високу інтенсивність на зображенні, усі вокселі, що мають інтенсивність більшу за 210 перетворюються на 170.

Після цього кожне зображення обрізається таким чином, щоб за будь-яким виміром навколо легень було тільки 10 пікселів.



Мал. 9: зображення етапів препроцесінгу

4.5.2. Перетворення даних

Для того, щоб передати дані в нейронну мережу, необхідно здійснити декілька кроків. Оскільки розмір зображення досить великий, то при навчанні нейронної моделі виникає переповнення пам'яті, тому для зменшення об'єму даних використовуються шматки зображення (далі патчі) розміром $128 \times 128 \times 128 \times 1$.

Вибиралися патчі таким чином: 70% мали хоча б один вузол, а 30% вибиралися рандомним чином, тому можуть або мати вузли, або ні. Це забезпечує достатню кількість негативних зразків.

Якщо деякий патч при виборі опинявся за межами легень, то ця зона заповнювалася значенням 170, так само як при препроцесінгу.

Для більш зручної роботи з патчами також було введено правило, що відстань від вузола до границі патча мала складати не менше, ніж 12 пікселів.

Оскільки нейронні мережі схильні до перенавчання, то для запобігання цьому застосовуються такі методи як переворот зображення,

віддзеркалення, зміна розміру тощо, щоб урізноманітнити зразки в датасеті.

В даному випадку використовувалися такі методи: випадковим чином патчі перегортали зліва направо та змінювали розмір з деяким коефіцієнтом з діапазону від 0.8 до 1.15.

Дані методи та їх параметри були підібрані емпірично.

4.5.3. Архітектура нейронної мережі

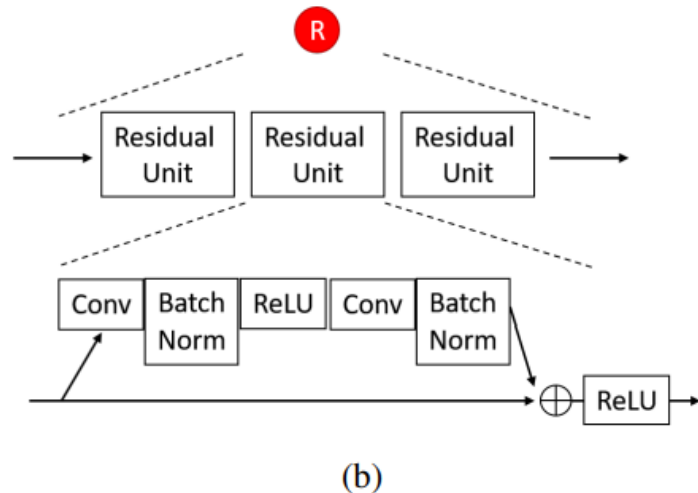
Дана мережа складається з двох частин: частина для розпізнавання підозрілих елементів та класифікації. Розглянемо архітектуру згорткової нейронної мережі для розпізнавання.

Основною ідеєю даної мережі було використання бази від U-net — нейронної мережі для сегментації біомедичних зображень — та RPN — мережі для розпізнавання об'єктів на зображеннях різного масштабу.

Нейронна мережа складається з двох кроків: feedforward (прямий) та feedback (зворотного).

Feedforward крок починається з двох згорткових шарів розмірності $3 \times 3 \times 3$ з 24 каналами. За ними слідує чотири 3D residual блоки, які чередуються з чотирма 3D max pooling шарами, розмір pooling — $2 \times 2 \times 2$ з кроком 2.

Кожен 3D residual block (залишковий блок) складається з трьох residual комірок. Кожна комірка складається зі згорткового шару, нормалізації з активацією ReLU, ще одного згорткового шару та ще однієї нормалізації. Візуалізація цього на малюнку нижче.



Мал. 10: структура залишкового блоку

Зворотний крок складається з двох deconvolutional шарів і двох combining unit. Кожен deconvolutional шар має розмір ядра і крок 2.

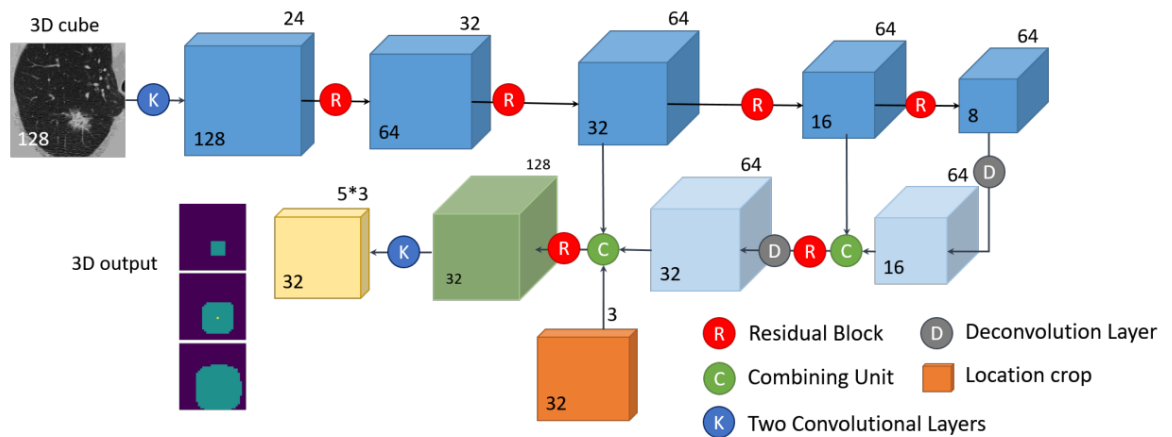
Кожен combining unit складається зі збережених на деякому етапі результатів прямого та зворотного кроку, які збираються разом і передаються в залишковий блок. Також додається деякий тензор, що містить додаткову інформацію.

Цей тензор містить інформацію про розташування вузла, оскільки його розміщення може впливати на те чи є вузол злоякісним, чи ні. Даний тензор містить карти ознак розмірністю $32 \times 32 \times 32 \times 3$, де кожна карта відповідає якій-небудь координаті. На кожній осі максимальні і мінімальні значення нормалізуються до 1 та -1 відповідно, що відповідає двом кінцям легені.

Отже, карта ознак отримана на цьому кроці має розмірність $32 \times 32 \times 32 \times 131$.

Після цього слідує два згорткових шари розмірності $1 \times 1 \times 1$ з кількістю каналів в 64 та 15 відповідно.

Результуючий тензор має розмірність $32 \times 32 \times 32 \times 15$. Нижче можна розглянути візуалізацію архітектури нейронної мережі N-N Net.



Мал. 11: Загальна архітектура N-N Net

Після цього вихідний тензор трансформують до вигляду $32 \times 32 \times 32 \times 3 \times 5$. Останні дві розмірності відповідають анкорам та регресорам.

В кожній позиції мережа має три анкори різних масштабів, що відповідають трьом bounding boxes з довжиною 10, 30 і 60 мм відповідно. Таким чином, загалом є $32 \times 32 \times 32 \times 3$ анкорних рамок.

Для регресору маємо п'ять значень: інформацію про кожну з трьох координат центру елемента, класифікацію — вузол чи не вузол та розмір bounding box для елемента відносно його центру.

Для того, щоб визначитися чи є отриманий елемент, на який посилається анкор, вузлом чи ні, використовується порівняння з цільовими значеннями вузлів в даному знімку.

Після цього використовується метрика Intersection over Union, яка розраховується нижченаведеним чином.

Нехай GT — це ground truth, тобто відомий об'єм, який містить вузол, а S — segmentation mask, тобто передбачений моделлю об'єм, який за думкою моделі містить вузол. Тоді True Positive (істинно вірні) має формулу $TP = GT \cap S$, False Positive — $FP = (GT \cup S) \setminus GT$, а False Negative — $FN = (GT \cup S) \setminus S$.

А власне метрика розраховується за наступною формулою:

$$IoU = \frac{TP}{(TP+FP+FN)}$$

Ті елементи, які мають значення більше 0.5 вважаються вузлами, а ті елементи, які мають значення менше за 0.02 не мають вузлів. Усі інші елементи відкидаються.

4.5.4. Подальша класифікація

Для того, щоб дійсно сказати чи є у пацієнта рак на основі виявлених вузлів необхідно провести подальшу класифікацію. Для цього з усього отриманого масиву вузлів вибирається 5, які мають найвищий confidence score (найвищий рівень точності) за результатами навчання N-Net. Для запобігання упередженості моделі під час навчання вибираються вузли з деякою ймовірністю, що пропорційна їх confidence score.

Після даного кроку необхідно створити деяку модель, яка зможе за деякими ознаками визначити чи є дані вузли раковими чи ні.


Через обмежену кількість навчальних прикладів не має сенсу будувати окрему нейронну мережу для подальшої класифікації, оскільки це може призвести до перенавчання. Альтернативним варіантом є використання навченої N-Net з фази object detection.

Для кожного вибраного на етапі навчання потенціального вузла вибирається шматок зображення розміром $96 \times 96 \times 96 \times 1$, центром якого є вузол (даний шматок є меншим, ніж на попередній фазі), подається на вхід N-Net і на виході отримується останній згортковий шар N-Net, який має розмір $24 \times 24 \times 24 \times 128$.

Центральні $2 \times 2 \times 2$ вокселі кожного потенціального вузла витягуються і проводиться max pooling, що дозволяє отримати 128-вимірний вектор ознак.

Спочатку ознаки усіх п'яти вузлів передаються до деякого повнозв'язного шару, щоб отримати п'ять 64-вимірних ознак. Потім ці ознаки комбінуються, отримуючи одну 64-вимірну ознаку за допомогою max pooling. Вектор ознак подається до другого повнозв'язного шару з

функцією активації сигмоїдою для отримання ймовірності раку в даному випадку.



Мал. 12: отримання ознак для визначення ймовірності наявності раку

Цей метод може бути корисним, якщо існує нелінійна кореляція між вузлами. Недолік полягає в тому, що він складно інтерпретований на етапі інтеграції, оскільки відсутня пряма залежність між кожним вузлом та ймовірністю раку.

Існує проблема в MaxP. Якщо у пацієнта є рак, але деякі злоякісні вузли були пропущені на етапі object detection, цей метод буде відносити причину раку до виявлених, але доброякісних вузлів, що збільшить ймовірність підозрілості інших подібних доброякісних вузлів у наборі даних. Це, очевидно, не має сенсу. Ми вводимо гіпотетичний фіктивний вузол і визначаємо його ймовірність раку як P_d . Остаточна, ймовірність раку становить:

$$P = 1 - (1 - P_d) \prod_i (1 - P_i).$$

Отже, для задачі object detection використовується N-Net, за найімовірнішими п'ятьма результатами якої визначається чи є в пацієнта рак, чи немає.

При тестуванні дана нейронна мережа дає результат в 87% на AUC-метриці і 90% при тренуванні.

Розділ 5. Практична частина


В якості практичної частини було реалізовано архітектуру N-Net мовою Python із застосування бібліотеки для машинного навчання PyTorch.

Реалізація має чотири кроки: препроцесінг даних, аналіз даних, перетворення даних, тренування та тестування.

5.1. Препроцесінг даних

Для подальшого аналізу та можливості натренувати модель дані необхідно перетворити, щоб збільшити розпізнавальну здатність та викинути зайві дані.


У минулому розділі вже було розглянуто алгоритм препроцесінгу даних. В практичній реалізації також слідували йому. Нижче зображено зовнішній вигляд цих перетворень.



Мал. 13: етапи препроцесінгу даних


5.2. Аналіз даних

Розглянемо які є особливості та закономірності в даних. По-перше, подивимось на розподіл за одиницями Хаунсфілда, тобто яка кількість вокселів має те чи інше значення.



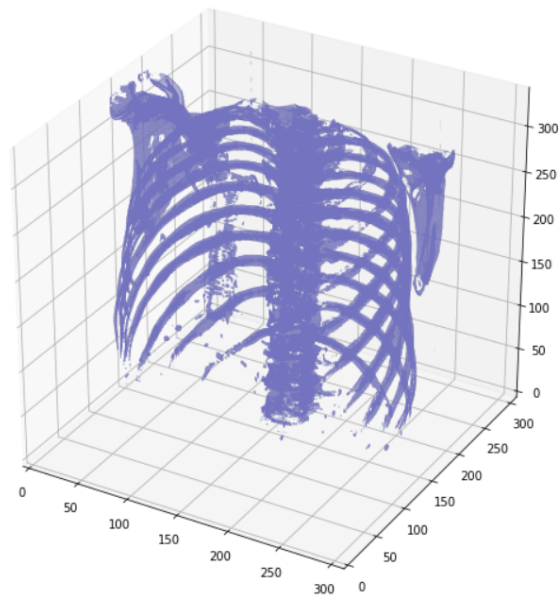
Мал. 14: розподіл за одиницями Хаунсфілда

Для того, щоб дізнатися більше про зовнішній вигляд легенів з вузлами та без, розглянемо перетворені з деяким порогом — для зміни кольорової гамаи — дані.




Мал. 15: перетворені зображення легень: світлі плями — це більш щільні ділянки даних

Також задля більш повного розуміння вигляду даних за одиницями Хаунсфілду було розглянуто 3D візуалізації легень.




Мал. 16: кісткові структури в грудній порожнині



Мал. 17: рисунок легневих структур щільніших за повітря


5.3. Доповнення даних



Мал. 18: легені після препроцесінгу (зліва) та після перетворення (справа)

Після двох етапів іде ітап доповнення даних задля більшої варіативності. Зображення повертаються, обрізаються, робиться балансування вибірки за позитивними та негативними зразками.

На малюнку вище продемонстровано результати обробки зображень після етапу препроцесінгу та після етапу перетворення. На малюнку нижче можна більш детально зрозуміти що відбувається на розглядуваному етапі.




Мал. 19: отримання доповненого зображення

Тобто: зображення, яке є позитивним зразком, з нього витягується елемент, який містить вузол, зменшується до бажаних розмірів та центрується.

5.4. Тренування та тестування


Після цього відбувається етап тренування моделі. Розглянемо отримані значення loss-функції за епохами тренування та валідації.



Мал. 20: loss-функція на етапах тренування та валідації

Отже, на малюнку можна побачити деяке перенавчання моделі, але воно є доволі незначним, в 0.6. Loss-функція на етапі тренування швидко спадає. Така поведінка визначена невеликою кількістю даних для тренування, оскільки тренування на повному датасеті вимагає значних обчислювальних потужностей. Але навіть така модель здатна з деякою точністю передбачати легеневі аномалії.

Розглянемо нижче приклад розпізнавання моделлю деякого вузла в легенях.



Мал. 21: приклад розпізнавання вузла в легенях

Висновки

Було розглянуто технологію КТ-сканування, вигляд знімків та їх особливості, деякі ознаки наявності патологій і алгоритми машинного навчання, які дозволяють автоматизувати процес виявлення аномалій.

Серед розглянутих алгоритмів були алгоритми, які як використовували глибоке навчання, так і ні. Серед алгоритмів глибокого навчання вивчалися згорткові нейронні мережі, які були розроблені для біомедичних цілей.

Для практичної реалізації було обрано N-Net. Її було реалізовано засобами мови Python.

За отриманими результатами можна сказати, що незважаючи на невеликі розміри тренувальної вибірки, модель навчилася вельми успішно і порівняно швидко.

З даної роботи можна зробити такі висновки: згорткові нейронні мережі є успішним засобом розпізнавання об'єктів на біомедичних зображеннях, що дозволяє їх використовувати для створення продуктів, які можна використовувати в реальних умовах.

Список використаних джерел

1. O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, 2015, pp. 234–241.
2. J. S. Duncan and N. Ayache, "Medical image analysis: Progress over two decades and the challenges ahead," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 22, no. 1, pp. 85–106, 2000.
3. J. Ding, A. Li, Z. Hu, and L. Wang, "Accurate Pulmonary Nodule Detection in computed tomography images using deep convolutional neural networks," in Medical Image Computing and Computer-Assisted Intervention 2017, ser. Lecture Notes in Computer Science. Springer, Cham, Sep. 2017, pp. 559–567.
4. B. Van Ginneken, S. G. Armato, B. de Hoop, S. van Amelsvoort-van de Vorst, T. Duindam, M. Niemeijer, K. Murphy et al., "Comparing and combining algorithms for computer-aided detection of pulmonary nodules in computed tomography scans: the anode09 study," Medical Image Analysis, vol. 14, no. 6, pp. 707–722, 2010.
5. S. G. Armato, G. McLennan, L. Bidaut, M. F. McNittGray, C. R. Meyer, A. P. Reeves, B. Zhao et al., "The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans," Medical Physics, vol. 38, no. 2, pp. 915–931, 2011.
6. A. A. A. Setio, F. Ciompi, G. Litjens, P. Gerke, C. Jacobs, S. J. van Riel, M. M. W. Wille et al., "Pulmonary nodule detection in CT images: false positive reduction using multi-view convolutional networks," IEEE Transactions on Medical Imaging, vol. 35, no. 5, pp. 1160–1169, 2016.
7. Q. Dou, H. Chen, L. Yu, J. Qin, and P.-A. Heng, "Multilevel contextual 3-d cnns for false positive reduction in pulmonary nodule detection,"

- IEEE Transactions on Biomedical Engineering, vol. 64, no. 7, pp. 1558–1567, 2017.
8. A. A. A. Setio, A. Traverso, T. de Bel, M. S. Berens, C. v. d. Bogaard, P. Cerello, H. Chen et al., “Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: the luna16 challenge,” arXiv preprint arXiv:1612.08012, 2016.
 9. Sharmila Nageswaran, G. Arunkumar, Anil Kumar Bisht, Shivalal Mewada, J. N. V. R. Swarup Kumar, Malik Jawarneh and Evans Asenso “Lung Cancer Classification and Prediction Using Machine Learning and Image Processing”, 2019
 10. Hasib Zunair, Aimon Rahman, Nabeel Mohammed, Joseph Paul Cohen “Uniformizing Techniques to Process CT scans with 3D CNNs for Tuberculosis Prediction”, 2020
 11. Mpho Mokoatle, Vukosi Marivate, Darlington Mapiye, Riana Bornman, Vanessa. M. Hayes “A review and comparative study of cancer detection using machine learning: SBERT and SimCSE application”, 2023
 12. Pragya Chaturvedi et al “Prediction and Classification of Lung Cancer Using Machine Learning Techniques”, IOP Conf. Ser.: Mater. Sci. Eng, 2021
 13. Радіологія (променева діагностика та променева терапія): навчальний посібник для студ. вищ. медичних навч. закл. / М.М. Ткаченко та ін.; за ред. М.М. Ткаченка. — К.: Книга-плюс, 2011. — С. 182-226
 14. United States Cancer Statistics Data Visualizations: <https://gis.cdc.gov/Cancer/USCS/#/AtAGlance/>
 15. LUng Nodule Analysis 2016: <https://luna16.grand-challenge.org/>
 16. Normal CT chest: <https://radiopaedia.org/cases/normal-ct-chest>

17. The solution of team 'grt123' in DSB2017:

<https://github.com/lfz/DSB2017>

18. Full preprocessing tutorial:

<https://www.kaggle.com/code/tzeny15/full-preprocessing-tutorial>

Ім'я користувача:
Оноцький В'ячеслав ФКомпНаук

ID перевірки:
1015628589

Дата перевірки:
16.06.2023 16:49:41 EEST

Тип перевірки:
Doc vs Internet + Library

Дата звіту:
16.06.2023 16:50:10 EEST

ID користувача:
100002816

Назва документа: КарпенкоАлісаЮріївна

Кількість сторінок: 40 Кількість слів: 6465 Кількість символів: 53597 Розмір файлу: 2.63 MB ID файлу: 1015275268

0.99% Схожість

Найбільша схожість: 0.28% з джерелом з Бібліотеки (ID файлу: 1015222137)

0.8% Джерела з Інтернету

96

Сторінка 42

0.57% Джерела з Бібліотеки

57

Сторінка 42

0% Цитат

Вилучення цитат вимкнене

Вилучення списку бібліографічних посилань вимкнене

0% Вилучень

Немає вилучених джерел

Модифікації

Виявлено модифікації тексту. Детальна інформація доступна в онлайн-звіті.

Замінені символи

7

КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ТАРАСА ШЕВЧЕНКА

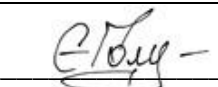
СИСТЕМА ЗАПОБІГАННЯ ТА ВИЯВЛЕННЯ АКАДЕМІЧНОГО ПЛАГІАТУ

Довідка про оригінальність кваліфікаційної роботи за освітнім рівнем бакалавр

Експертна оцінка роботи науковим керівником :

Робота студентки 4-го курсу Карпенко Аліси Юріївни «Дослідження легеневих аномалій шляхом використання машинного навчання» виконана самостійно, при цьому обсяг цитувань та запозичень становить 0.99% і не перевищує норму. Усі запозичення мають посилання на відповідне джерело.

Науковий керівник:

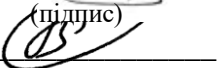


(підпис)

Голубева К.М.

(ПБ)

Оператор:



(підпис)

Оноцький В.В.

(ПБ)

**Відгук наукового керівника
на кваліфікаційну роботу бакалавра на тему:
«Дослідження легеневих аномалій шляхом використання машинного
навчання»
студентки 4-го курсу
факультету комп'ютерних наук та кібернетики
Київського національного університету імені Тараса Шевченка
Карпенко Аліси Юріївни**

Розглянута робота присвячена дослідженню можливостей машинного навчання, зокрема глибокого навчання, для розв'язку задачі пошуку легеневих аномалій, а саме легеневих вузлів, які сигналізують про можливу наявність раку легенів.

Зважаючи на невтішну світову статистику щодо захворюваності на рак легенів і на те, що більшість випадків діагностують занадто пізно, проведення масових скринінгів та валідація їх результатів є на сьогоднішній день актуальною проблемою.

В роботі проведено глибокий аналіз літератури, що присвячена досліджуваній проблемі, послідовно та логічно викладено опис алгоритмів глибокого навчання, які здатні розв'язати поставлену задачу.

В практичній частині реалізовано одну з найкращих за своїми показниками мереж, які були створені для вирішення даної проблеми.

Серед недоліків роботи можна виділити те, що нейронна мережа навчалася на доволі малій кількості даних і розглянути її повні можливості не вдалося.

Вказані недоліки не зменшують цінності проведених досліджень та отриманих результатів. Вважаю, що кваліфікаційна робота студентки відповідає вимогам, які висуваються до бакалаврських робіт, і заслуговує на оцінку «відмінно», а її авторка заслуговує на присвоєння кваліфікації бакалавра.

Доцент кафедри обчислювальної математики
факультету комп'ютерних наук та кібернетики
Київського національного університету
імені Тараса Шевченка, доцент



Катерина ГОЛУБЄВА

Рецензія
на кваліфікаційну роботу бакалавра на тему:
«Дослідження легеневих аномалій шляхом використання машинного
навчання»
студентки 4-го курсу бакалавріату
факультету комп'ютерних наук та кібернетики
Київського національного університету імені Тараса Шевченка
Карпенко Аліси Юріївни

Підходи на базі машинного навчання успішно використовуються в багатьох галузях знань. У даній роботі досліджується ефективність таких підходів до задачі скринінгу раку легенів, до якої природно чином застосовуються алгоритми розпізнавання об'єктів, класифікації та детектування аномалій. Така задача безсумнівно важлива, оскільки серед чинників смертності від раку саме рак легенів є одним з основних.

Робота концентрується на дослідженні згорткових нейронних мереж, які ефективно використовуються для задач розпізнавання. Висвітлюються переваги та недоліки кожної архітектури, що є гарним підґрунтям для вибору архітектури для конкретної задачі.

Практична частина містить усі основні етапи розробки програмного продукту в сфері Data Science, отримані результати демонструють попередню обробку даних, моделювання та власне результати передбачення моделі.

Вважаю, що кваліфікаційна робота студентки Аліси Карпенко відповідає вимогам, які висуваються до бакалаврських робіт, і заслуговує на оцінку «відмінно», а її авторка заслуговує на присвоєння кваліфікації бакалавра.

Рецензент:

доктор фізико-математичних наук,
професор

Дмитро Номіровський