

ДЕРЖАВНИЙ УНІВЕРСИТЕТ  
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ  
НАВЧАЛЬНО-НАУКОВИЙ ІНСТИТУТ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ  
КАФЕДРА КОМП'ЮТЕРНОЇ ІНЖЕНЕРІЇ

**КВАЛІФІКАЦІЙНА РОБОТА**  
на тему: «СИСТЕМА АНАЛІЗУ МЕДИЧНИХ  
ЗОБРАЖЕНЬ ДЛЯ ВИЯВЛЕННЯ COVID-19 З  
ВИКОРИСТАННЯМ ШІ»

на здобуття освітнього ступеня магістра  
зі спеціальності 123 Комп'ютерна інженерія  
(код, найменування спеціальності)  
освітньо-професійної програми Комп'ютерні системи та мережі  
(назва)

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

\_\_\_\_\_  
(підпис)

*Катерина Западенко*  
\_\_\_\_\_  
Ім'я, ПРІЗВИЩЕ здобувача

Виконав: здобувач(ка) вищої освіти гр. КСДМ-62  
Катерина ЗАПАДЕНКО  
Ім'я, ПРІЗВИЩЕ

Керівник: Людмила АСЕСВА  
науковий ступінь,  
вчене звання Ім'я, ПРІЗВИЩЕ

Рецензент: \_\_\_\_\_  
науковий ступінь,  
вчене звання Ім'я, ПРІЗВИЩЕ

# ДЕРЖАВНИЙ УНІВЕРСИТЕТ ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ

Навчально-науковий інститут Інформаційних технологій

Кафедра Комп'ютерної інженерії

Ступінь вищої освіти Магістр

Спеціальність 123 «Комп'ютерна інженерія»

Освітньо-професійна програма Комп'ютерні системи та мережі

**ЗАТВЕРДЖУЮ**

Завідувач кафедру Наталія ЛАЩЕВСЬКА

Ім'я, ПРІЗВИЩЕ

«\_\_\_\_\_» \_\_\_\_\_ 2024р.

## ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

Западенко Катерина Олександрівні

(прізвище, ім'я, по батькові)

1. Тема кваліфікаційної роботи: «Система аналізу медичних зображень для виявлення COVID-19 з використанням ШІ»

керівник роботи: Асєєва Людмила Анатоліївна, доктор філософії., доцент

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом Державного університету інформаційно-комунікаційних технологій від «15» жовтня 2024р. №320,

2. Строк подання кваліфікаційної роботи «29» грудня 2024р.

3. Вихідні дані до кваліфікаційної роботи: У сучасних умовах пандемії COVID-19 важливим завданням є розробка ефективних засобів діагностики захворювання. Одним із перспективних підходів є використання штучного інтелекту для аналізу медичних зображень, зокрема рентгенівських знімків легень. Ця робота присвячена створенню системи автоматичного виявлення COVID-19 на основі нейронної мережі VGG-16, реалізованої з використанням бібліотеки Keras у середовищі програмування Python. Система спрямована на підвищення точності та швидкості діагностики, що може сприяти більш ефективному реагуванню на виклики, пов'язані з пандемією.

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

- Теоретичні основи про штучний інтелект та роль в медицині
- Системи класифікації зображень виявлення COVID-19
- Розробка системи аналізу для класифікації зображень
- Висновки класифікації зображень

5. Перелік графічного матеріалу: презентація

Мета, об'єкт, предмет дослідження

- Актуальність роботи
- Штучний інтелект і медицина
- Застосування в медицині
- Класифікація зображень для виявлення COVID-19
- Глибокі нейронні мережі
- Система класифікації медичних зображень для виявлення COVID-19
- Підготовка зображення

8. Навчання моделі
  9. Виведення результатів
  10. Результат аналізу
  11. Висновки
  12. Публікації та апробація роботи
6. Дата видачі завдання «01» вересня 2024р.

## КАЛЕНДАРНИЙ ПЛАН

| № з/п | Назва етапів кваліфікаційної роботи  | Строк виконання етапів роботи | Примітка |
|-------|--------------------------------------|-------------------------------|----------|
| 1     | Пошук та збір теоретичної інформації | 09.10-15.10.2024              | Виконано |
| 2     | Обробка матеріалу                    | 16.10-18.10.2024              | Виконано |
| 3     | Підготовка даних для класифікації    | 18.10-21.10.2024              | Виконано |
| 4     | Розробка моделі                      | 21.10-01.11.2024              | Виконано |
| 5     | Аналіз результатів                   | 01.11-02.11.2024              | Виконано |
| 6     | Розробка презентації                 | 02.12-03.12.2024              | Виконано |
| 7     | Передзахист                          | 09.12-11.12.2024              | Виконано |
| 8     | Здача в деканат                      | 20.12-29.12.2024              |          |

Здобувач вищої освіти

\_\_\_\_\_  
(підпис)

Катерина Западенко  
(Ім'я, ПРІЗВИЩЕ)

Керівник кваліфікаційної роботи

\_\_\_\_\_  
(підпис)

Людмила Асєєва  
(Ім'я, ПРІЗВИЩЕ)

## РЕФЕРАТ

Текстова частина кваліфікаційної роботи на здобуття освітнього ступеня магістр: 70 стор., 26 рис., 2 табл., 21 джерел.

*Мета роботи* - дослідження можливостей використання попередньо навчених моделей для класифікації медичних зображень та їхнього застосування для виявлення COVID-19.

*Об'єкт дослідження* - Процеси діагностики COVID-19 на основі аналізу медичних зображень.

*Предмет дослідження* – Методи, алгоритми та технології штучного інтелекту, що застосовуються для аналізу медичних зображень у задачах виявлення COVID-19.

*Завданням роботи є:*

1. Провести огляд існуючих методів класифікації медичних зображень за допомогою ІІІ.
2. Вивчити особливості та ефективність попередньо навчених моделей, таких як VGG-16.
3. Реалізувати практичну систему для класифікації медичних зображень із метою виявлення COVID-19 на базі Keras.
4. Провести оцінку якості роботи моделі та обговорити можливі шляхи її вдосконалення.

КЛЮЧОВІ СЛОВА: ШТУЧНИЙ ІНТЕЛЕКТ, КЛАСИФІКАЦІЯ, ЗГОРТКОВІ НЕЙРОННІ МЕРЕЖІ, COVID-19, VGG-16, KERAS, МЕДИЧНІ ЗОБРАЖЕННЯ, АНАЛІЗ ЗОБРАЖЕНЬ, МЕТОДИ, РЕНТГЕНІВСЬКІ ЗНІМКИ, ДОСЛІДЖЕННЯ.

## ABSTRACT

The text part of the qualification work for obtaining a master's degree: 70 pages, 26 figures, 2 tables, 21 sources.

The purpose of the work is to investigate the possibilities of using pre-trained models for medical image classification and their application for COVID-19 detection.

The object of the research is COVID-19 diagnostic processes based on medical image analysis.

The subject of research is artificial intelligence methods, algorithms, and technologies used for medical image analysis in COVID-19 detection tasks.

The objectives of the work are:

1. To review existing methods for classifying medical images using AI.
2. To study the features and effectiveness of pre-trained models such as VGG-16.
3. To implement a practical system for classifying medical images for the purpose of detecting COVID-19 based on Keras.
4. To assess the quality of the model and discuss possible ways to improve it.

KEYWORDS: ARTIFICIAL INTELLIGENCE, CLASSIFICATION, CONVULSIVE NEURAL NETWORKS, COVID-19, VGG-16, KERAS, MEDICAL IMAGES, IMAGE ANALYSIS, METHODS, X-RAY IMAGES, RESEARCH.





## **ЗМІСТ**

|                                                                                          |           |
|------------------------------------------------------------------------------------------|-----------|
| <b>РОЗДІЛ 1. ОСНОВИ ШТУЧНОГО ІНТЕЛЕКТУ В МЕДИЧНІЙ ДІАГНОСТИЦІ .....</b>                  | <b>12</b> |
| 1.1 Штучний інтелект та застосування в медицині .....                                    | 12        |
| 1.2 Переваги та недоліки використання ШІ для аналізу в медичній діагностиці .....        | 17        |
| 1.3 Класифікація зображень для виявлення COVID-19 .....                                  | 28        |
| <b>РОЗДІЛ 2. ПОПЕРЕДНЬО НАВЧЕНІ МОДЕЛІ ДЛЯ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ.....</b>               | <b>35</b> |
| 2.1 Огляд глибоких нейронних мереж для класифікації зображень .....                      | 35        |
| 2.2 Попередньо навчені моделі: визначення та принцип роботи .....                        | 49        |
| 2.3 VGG-16 для діагностики COVID-19 .....                                                | 54        |
| 2.4 Keras: Інструменти та бібліотеки для обробки зображень .....                         | 61        |
| <b>РОЗДІЛ 3. РЕАЛІЗАЦІЯ КЛАСИФІКАЦІЇ МЕДИЧНИХ ЗОБРАЖЕНЬ ДЛЯ ВИЯВЛЕННЯ COVID-19 .....</b> | <b>68</b> |
| 3.1 Підготовка набору медичних зображень для класифікації .....                          | 68        |
| 3.2 Класифікація зображень на попередньо навчених моделях .....                          | 73        |
| 3.3 Обговорення та аналіз отриманих результатів .....                                    | 78        |
| <b>ВИСНОВОК.....</b>                                                                     | <b>83</b> |
| <b>ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ .....</b>                                                 | <b>85</b> |
| <b>ДОДАТОК А.</b>                                                                        |           |
| <b>ДОДАТОК Б.</b>                                                                        |           |
| <b>ДОДАТОК В.</b>                                                                        |           |
| <b>ДОДАТОК Г.</b>                                                                        |           |

## ВСТУП

Пандемія COVID-19 глибоко вплинула на глобальні системи охорони здоров'я, зайнявши величезні ресурси та підкресливши необхідність швидкої, точної діагностики та лікування. Оскільки попит на діагностичні інструменти різко зріс, традиційні методи, такі як тести полімеразної ланцюгової реакції (ПЛР), часто виявлялися трудомісткими, ресурсомісткими та недоступними в багатьох регіонах. Це підкреслило актуальність інноваційних рішень для оптимізації та вдосконалення діагностичних процесів.

Аналіз медичних зображень, зокрема з використанням рентгенівських знімків грудної клітки і комп'ютерної томографії (КТ), став багатообіцяючим підходом для виявлення COVID-19 у пацієнтів. Однак інтерпретація цих зображень вручну може бути викликана людськими помилками, мінливістю та затримками. Цей виклик дає можливість штучному інтелекту (ШІ) революціонізувати діагностичний ландшафт, забезпечуючи автоматизований, ефективний і високоточний аналіз медичних зображень.

Крім того, пандемія дала поштовх до розробки нових методів співпраці між інженерами, медичними працівниками та дослідниками, стимулюючи створення міждисциплінарних підходів для вирішення складних викликів у сфері охорони здоров'я. Інтеграція штучного інтелекту у процеси діагностики відкриває перспективи для масштабованих і гнучких рішень, які можуть бути адаптовані до інших захворювань чи майбутніх глобальних криз. Важливо зазначити, що подібні системи не лише підтримують лікарів, але й слугують інструментом для навчання та підвищення якості медичних послуг. Дослідження в цьому напрямі не тільки сприяє розв'язанню нагальних проблем, а й формує фундамент для створення інноваційних технологій, які змінять майбутнє медицини.

Використання попередньо навчених моделей глибоких нейронних мереж, таких як VGG-16, дозволяє швидко адаптувати їх до нових завдань, що скорочує час на розробку та впровадження рішень. Це забезпечує більш ефективну

класифікацію медичних зображень, знижуючи ймовірність помилок діагностики та пришвидшуючи ухвалення рішень, що є особливо важливим в умовах пандемій.

Паралельно з цим зростає потреба в розробці відкритих і доступних платформ, які дозволяють інтегрувати дані з різних джерел та вдосконалювати алгоритми аналізу медичних зображень. Використання таких платформ сприяє міжнародній співпраці, обміну даними та стандартизації підходів, що є критично важливим для боротьби з глобальними пандеміями. Наступне, Необхідно звернути особливу увагу на етичні питання використання штучного інтелекту в медицині, зокрема конфіденційності даних пацієнтів, прозорості алгоритмів і забезпеченню справедливості діагностичних рішень. У цьому контексті впровадження попередньо навчених моделей не тільки демонструє технічний прогрес, але й дає змогу глибше усвідомити відповідальність за розробку технологій, які безпосередньо впливають на здоров'я та життя людей. Таким чином, розробка та впровадження таких систем є не лише науковим завданням, але й важливим кроком до побудови більш стійкої та ефективної системи охорони здоров'я на глобальному рівні.

Метою цієї дипломної роботи є аналіз можливостей використання попередньо навчених моделей для класифікації медичних зображень з акцентом на виявлення COVID-19. Використовуючи сучасні алгоритми машинного навчання, зокрема моделі глибокого навчання, система має на меті допомогти медичним працівникам, надаючи швидку та надійну діагностичну інформацію. Завдяки автоматизації інтерпретації зображень ця система може підвищити ефективність діагностики, зменшити навантаження на медичний персонал і покращити результати лікування пацієнтів, особливо в регіонах з обмеженим доступом до спеціалізованої медичної експертизи.

## РОЗДІЛ 1. ОСНОВИ ШТУЧНОГО ІНТЕЛЕКТУ В МЕДИЧНІЙ ДІАГНОСТИЦІ

### 1.1 Штучний інтелект та застосування в медицині

Штучний інтелект (ШІ) — це сфера інформатики та техніки, яка зосереджена на розробці систем і алгоритмів, які традиційно пов'язують поведінку з когнітивними функціями людини. Системи штучного інтелекту мають на меті імітувати або відтворювати такі здібності, як навчання, міркування, вирішення проблем, сприйняття та розуміння природної мови.

За своєю суттю ШІ працює через розробку та реалізацію алгоритмів, які дозволяють комп'ютерам інтерпретувати складні дані, розпізнавати закономірності та приймати рішення чи прогнози. У цих системах зазвичай використовується машинне навчання, підмножина штучного інтелекту, яка використовує статистичні методи, щоб дозволити моделям самостійно вдосконалюватися з часом на основі вхідних даних. Машинне навчання саме по собі включає різні методи, такі як контрольоване навчання, неконтрольоване навчання та навчання з підкріпленням, які застосовуються залежно від природи проблеми та доступності даних.

Більш просунуті підмножини штучного інтелекту включають глибоке навчання, яке використовує багатошарові нейронні мережі для обробки величезних обсягів даних у спробі віддзеркалити багатошарову обробку людського мозку. Дослідження штучного інтелекту також охоплюють такі галузі, як обробка природної мови, яка дозволяє комп'ютерам інтерпретувати та створювати людську мову, і комп'ютерне зір, яке зосереджується на вилученні та інтерпретації візуальних даних із середовища.

ШІ можна класифікувати на два основні типи: вузький ШІ, який призначений для конкретних завдань (наприклад, мовний переклад, розпізнавання зображень), і загальний ШІ, теоретична форма ШІ, яка буде демонструвати людську універсальність і розуміння різноманітних завдань

та домени. У той час як вузький штучний інтелект широко використовується в додатках сьогодні, загальний штучний інтелект залишається в основному бажаним, а значні теоретичні та практичні проблеми ще належить вирішити.

Штучний інтелект суттєво вплинув на сучасну медицину, створивши нові можливості для діагностики, персоналізованого лікування та ефективності охорони здоров'я. Використання штучного інтелекту в медицині охоплює різноманітні сфери, як-от прогнозна аналітика, допомога, орієнтована на пацієнта, і прийняття клінічних рішень. Системи штучного інтелекту добре справляються з системою аналізом великих наборів даних із таких джерел, як електронні медичні записи, зображення та портативні пристрої, щоб передбачити початок захворювання, оптимізувати лікування та підтримувати моніторинг пацієнтів у режимі реального часу. Взяти до прикладу, алгоритми машинного навчання використовують в кардіології для раннього виявлення таких станів, як фібриляція передсердь, з використанням переносних пристроїв, таких як схвалений FDA додаток Kardia та Apple Watch, які дозволяють віддалено контролювати та обмінюватися даними з постачальниками медичних послуг. Цей підхід не тільки дозволяє раннє втручання, але й сприяє більш проактивній формі управління здоров'ям.[1][2]

У персоналізованій медицині ШІ покращує так звану «модель 4P»: прогностичну, профілактичну, персоналізовану та спільну допомогу. Інструменти, які керуються штучним інтелектом, у таких галузях, як ендокринологія, наприклад система безперервного моніторингу глюкози, розроблена Medtronic і IBM Watson, надають пацієнтам оновлення в реальному часі та прогнозу аналітику для кращого лікування діабету. Ці додатки підкреслюють залучення пацієнтів, дозволяючи безперервний моніторинг і індивідуальні коригування лікування на основі індивідуальних шаблонів даних, сприяючи підвищенню автономії пацієнта та покращенню результатів.[2]

Окрім того, що програми штучного інтелекту в аналізі зображень, як і

ті, що використовуються в гастроентерології та радіології, покладаються на згорткові нейронні мережі для виявлення відхилень в ендоскопічних або радіологічних зображеннях, таких як виявлення поліпів товстої кишки або легеневих вузликів. Ці інструменти допомагають клініцистам швидше та точніше діагностувати. Однак інтеграція штучного інтелекту в медицині також створює проблеми, зокрема, пов'язані з конфіденційністю пацієнтів, алгоритмічними упередженнями та необхідністю стандартизованої нормативної бази. Виникло занепокоєння щодо потенціалу штучного інтелекту посилити існуючі розбіжності в стані здоров'я через упередження в навчальних даних або обмежений доступ до передових технологій, що підкреслює важливість справедливості в розробці штучного інтелекту.

Діагностична візуалізація. Штучний інтелект, зокрема через використання алгоритмів глибокого навчання, як згорткові нейронні мережі, значно покращив точність та швидкість аналізу медичних зображень. У радіології ці системи продемонстрували майже людську, а іноді й перевищуючу, точність у виявленні аномалій на рентгенівських знімках, КТ та МРТ. Моделі ШІ, навчені на великих масивах даних зображень, можуть виявляти ознаки захворювань, таких як рак легенів, неврологічні розлади та серцево-судинні захворювання. Дослідження в дерматології показали, що алгоритми ШІ можуть класифікувати ураження шкіри з точністю, порівнянною з дерматологами, що дозволяє раніше діагностувати та лікувати рак шкіри. [3]

Прогнозний аналіз. Прогнозний аналіз в охороні здоров'я використовує ШІ для прогнозування результатів захворювання та розвитку здоров'я пацієнтів. Моделі машинного навчання, які працюють з даними з електронних медичних карток (ЕМК), були розроблені для прогнозування результатів пацієнтів, таких як повторні госпіталізації, ризик розвитку хронічних захворювань та рівень смертності. Такі моделі є важливими для стратифікації пацієнтів за рівнем ризику та ефективного розподілу ресурсів. Прогнозні моделі особливо корисні у відділеннях інтенсивної терапії та

невідкладної допомоги, оскільки в режимі реального часу попереджають лікарів про можливе погіршення стану пацієнтів.

Персоналізована медицина та фармакогеноміка. ШІ сприяє персоналізації планів лікування через аналіз даних пацієнтів, включаючи генетичну інформацію, для підбору індивідуальних терапій. Такий підхід особливо важливий в онкології, де системи ШІ можуть оцінювати генетику пухлини для підбору найефективніших ліків та протоколів лікування. Наприклад, у фармакогеноміці ШІ допомагає виявити генетичні маркери, пов'язані з реакцією на ліки, що дозволяє лікарям призначати медикаменти, які будуть найефективнішими для окремого пацієнта. Алгоритми машинного навчання дали змогу створювати персоналізовані протоколи лікування, які мінімізують побічні ефекти та підвищують ефективність терапії. [4]

Обробка природної мови в ШІ дозволяє вилучати інформацію з неструктурованих клінічних записів, ЕМК та медичної літератури. Алгоритми NLP можуть обробляти величезні обсяги текстових даних для ідентифікації релевантної медичної інформації, автоматизації документації, оптимізації робочих процесів та покращення клінічного прийняття рішень. NLP особливо корисна для ідентифікації фенотипів пацієнтів, аналізу описів симптомів та складання історій хвороб, що сприяє точнішій оцінці пацієнтів та покращує підтримку клінічних рішень.

Роботизована хірургія. ШІ-посилені роботизовані хірургічні системи набувають популярності в процедурах, що потребують високої точності. Автоматизовані системи, до прикладу, як хірургічна система da Vinci, використовуює алгоритми ШІ для оптимізації рухів хірургічних інструментів, забезпечуючи підвищену спритність та контроль. Поєднуючи обробку даних у режимі реального часу з робототехнікою, ці системи дозволяють хірургам виконувати складні мінімально інвазивні операції з підвищеною точністю, зменшеною травматизацією та коротшими термінами реабілітації пацієнтів. З постійним розвитком технології ШІ у сфері робототехніки ці системи з часом надаватимуть ще більшу автономію та точність в операційних. [5]

Отже, як висновок можна сказати, що тучний інтелект — це розділ комп'ютерних наук, спрямований на створення технологій та алгоритмів, що можуть імітувати людський інтелект для виконання складних завдань, таких як аналіз зображень, розпізнавання мовлення, ухвалення рішень та навіть творчий підхід до обробки даних. У сфері медицини ШІ виступає рушійною силою інновацій, що трансформують процеси виявлення, терапії та спостереження пацієнтів, дозволяючи проводити глибший аналіз клінічних даних з більшою точністю та швидкістю. Завдяки здатності обробляти великі обсяги інформації, ШІ уможлиблює персоналізацію лікування, зокрема у галузях, де традиційні методи не завжди були ефективними. Наприклад, використання алгоритмів машинного навчання для аналізу генетичних даних пацієнтів допомагає виявляти індивідуальні особливості та підбирати терапію, яка максимально відповідає конкретному пацієнту. Це значно змінює підходи в таких сферах, як онкологія та фармакологія, де точний підбір препаратів і дозування має вирішальне значення для результатів лікування. ШІ також надає нові інструменти для профілактичної медицини, адже здатен на основі історії хвороб, даних з електронних медичних карток та біометричних показників прогнозувати ризики розвитку хронічних захворювань. У практиці діагностики застосування ШІ дозволяє автоматизувати аналіз зображень, наприклад, рентгенівських знімків, що значно підвищує швидкість виявлення патологій. Важливо, що візуальні алгоритми ШІ можуть виконувати скринінг на ранніх етапах захворювань, зокрема рак легенів і меланома, що є життєво важливим для порятунку життя.

Окрім того, технології обробки природної мови, інтегровані в клінічну документацію та системи електронних медичних записів, сприяють автоматизації рутинних адміністративних завдань, звільняючи лікарів від значної частини адміністративного навантаження. Роботизовані системи які на основі штучного інтелекту, в хірургії дозволяють виконувати високоточні мінімально інвазивні операції, зменшуючи ризики ускладнень і прискорюючи реабілітацію пацієнтів.

Загалом, розвиток ШІ у медицині відкриває безпрецедентні можливості для покращення якості медичних послуг та підвищення ефективності лікування. Як фундаментальна технологія, ШІ обіцяє зміни не лише у підходах до лікування, а й у загальному управлінні охороною здоров'я, сприяючи створенню більш доступної, прогностичної та персоналізованої системи охорони здоров'я.

## **1.2 Переваги та недоліки використання ШІ для аналізу в медичній діагностиці**

У міру того, як впровадження ШІ в охорону здоров'я прискорюється, розуміння його потенційного впливу на медичну діагностику стає дедалі важливішим. Для постачальників медичних послуг штучний інтелект пропонує шлях до швидшої та точнішої діагностики, особливо в таких сферах, як радіологія, патологія та геноміка, де складність даних висока. Алгоритми штучного інтелекту можуть швидко просіювати великі обсяги медичних даних, виявляючи шаблони, які можуть бути пропущені під час традиційного аналізу. Це особливо корисно для діагностики рідкісних захворювань, коли великі набори даних можуть допомогти визначити аномалії з більшою точністю. Крім того, АІ дозволяє системам охорони здоров'я працювати з більшою стійкістю та адаптивністю, особливо в регіонах або практиках, які стикаються з обмеженими ресурсами.

Застосування штучного інтелекту у медичній діагностиці стало трансформаційною силою в сучасній охороні здоров'я. Використовуючи алгоритми машинного навчання, доповнений та вдосконалений аналіз зображень і прогностні моделі, ШІ обіцяє підвищити точність, ефективність і доступність діагностичних процесів. Ця технологія має значний потенціал для покращення результатів лікування пацієнтів, дозволяючи раннє виявлення захворювань, зменшуючи людські помилки та оптимізуючи робочі процеси охорони здоров'я. Однак, як і будь-яка інновація, інтеграція ШІ в

медичну діагностику приносить як переваги, так і проблеми. Хоча переваги є значними, такі питання, як якість даних, етичні наслідки, витрати та регуляторні складності також потребують вирішення. За оцінками Statista обсяг ринку рішень ШІ для охорони здоров'я наразі становить близько \$28 млрд. Очікується, що найближчими роками ринок буде зростати з середньорічним темпом зростання у 37%, і вже до 2030 року досягне позначки у майже \$188 млрд. [6]

У цьому розділі розглядаються ключові переваги та недоліки використання ШІ для аналізу в медичній діагностиці, підкреслюючи його потенційний вплив на майбутнє охорони здоров'я.

### 1. Швидкість, ефективність та підвищена точність.

Впровадження штучного інтелекту в медицину революціонізує охорону здоров'я, підвищуючи швидкість, ефективність і точність діагностики, планування лікування та лікування пацієнтів. Використання можливостей штучного інтелекту не тільки призводить до кращих результатів лікування пацієнтів, але й дозволяє системам охорони здоров'я працювати ефективніше в швидкоплинному середовищі з обмеженими ресурсами. Нижче ми детально досліджуємо ці ключові переваги.

Діагностичні інструменти, засновані на ШІ, здатні оперативно аналізувати великі обсяги даних, часто в режимі реального часу. Це суттєво зменшує час, потрібний для обробки та інтерпретації даних візуалізації лабораторних результатів та інших медичних записів, що може покращити догляд за пацієнтами шляхом прискорення прийняття рішень і початку лікування.

Алгоритми машинного навчання можуть навчитися визначати шаблони в медичних даних з високою точністю. Аналізуючи величезні обсяги даних, системи штучного інтелекту допомагають зменшити людські помилки та забезпечити послідовний аналіз, особливо для складних випадків, що призводить до підвищення точності діагностичних результатів.

### 2. Раннє виявлення та профілактика

Здібності штучного інтелекту щодо швидкого й точного розпізнавання образів значно покращили раннє виявлення в багатьох галузях медицини, включаючи онкологію, кардіологію та неврологію. Наприклад, в онкології моделі штучного інтелекту, навчені на величезних наборах даних зображень, можуть ідентифікувати найменші аномалії на медичних зображеннях, які можуть вказувати на наявність пухлин, навіть на їх ранніх стадіях. Таке раннє виявлення має важливе значення для ракових захворювань, таких як рак молочної залози та рак легенів, де виявлення захворювання на початкових стадіях значно покращує ефективність лікування. Виявляючи ракові новоутворення на ранній стадії, діагностика за допомогою штучного інтелекту може зменшити потребу в інвазивних методах лікування та підвищити рівень виживаності, безпосередньо впливаючи на якість життя пацієнтів і витрати на охорону здоров'я.

У кардіології інструменти на основі штучного інтелекту аналізують дані електрокардіограм (ЕКГ), зображень серця та інших біомаркерів, щоб виявити ранні ознаки серцевих захворювань або аритмій. Ця здатність особливо корисна для виявлення безсимптомних станів, таких як фібриляція передсердь, яка може призвести до серйозних ускладнень, включаючи інсульт, якщо її не лікувати. Здатність штучного інтелекту виявляти такі стани на ранній стадії, часто за допомогою неінвазивного або мінімально інвазивного моніторингу, допомагає пацієнтам отримати своєчасну медичну допомогу та зменшує навантаження на служби екстреної та невідкладної допомоги.

Неврологічні захворювання, такі як хвороба Альцгеймера та Паркінсона, є іншими областями, де раннє виявлення має вирішальне значення. Штучний інтелект може аналізувати незначні зміни в зображенні мозку або поведінкових даних, щоб визначити ранні ознаки нейродегенеративних захворювань до того, як вони виявляться повномасштабними симптомами. Подаючи ранні попереджувальні ознаки, штучний інтелект дає змогу пацієнтам та їхнім сім'ям змінити спосіб життя,

почати прийом ліків або брати участь у терапевтичних втручаннях, які можуть уповільнити прогресування хвороби, підвищити рівень життя пацієнтів і скоротити довгострокові витрати на охорону здоров'я.

### 3. Профілактика: перехід від лікування до проактивного управління здоров'ям

Роль штучного інтелекту в профілактичній охороні здоров'я має трансформаційний характер, оскільки він дає змогу перейти від реактивного лікування до проактивного управління здоров'ям. Аналізуючи дані пацієнтів, штучний інтелект може ідентифікувати людей із підвищеним ризиком хронічних захворювань, таких як діабет, гіпертонія та хвороби серця, і надавати персоналізовані рекомендації щодо зміни способу життя або профілактичного лікування. Ця можливість є цінною для постачальників медичних послуг, які прагнуть реалізувати стратегії управління здоров'ям населення, зосереджуючись на групах ризику, щоб запобігти виникненню захворювань, а не просто лікувати захворювання, щойно вони виникають.

Здатність штучного інтелекту інтегрувати дані з різних джерел, включаючи електронні медичні записи (EHR), портативні пристрої та генетичні профілі, забезпечує більш персоналізований підхід до охорони здоров'я. Наприклад, прогностична аналітика може допомогти спрогнозувати наслідки пацієнтів, дозволяючи проактивні втручання та профілактичний догляд. Крім того, додатки на основі штучного інтелекту можуть надати пацієнтам освітню інформацію та підтримку, заохочуючи більшу участь у їхніх подорожах до здоров'я. Носимі технології — це ще одна сфера, де штучний інтелект покращує профілактичну допомогу, забезпечуючи постійний моніторинг стану здоров'я. Пристрої, які відстежують життєво важливі показники, такі як пульс, артеріальний тиск і рівень глюкози, збирають дані в режимі реального часу. Потім алгоритми штучного інтелекту можуть аналізувати ці дані, щоб виявити аномальні закономірності або ознаки ризиків для здоров'я. Наприклад, якщо переносний пристрій виявляє нерегулярний серцевий ритм або стрибки

артеріального тиску, штучний інтелект може попередити пацієнта та його медичного працівника, сприяючи негайному втручанню. Ці дані в реальному часі можуть запобігти перетворенню незначних проблем зі здоров'ям у надзвичайні ситуації, зменшити кількість госпіталізацій і підвищити безпеку пацієнтів.

Окрім індивідуального управління здоров'ям, передбачувані можливості штучного інтелекту відіграють важливу роль в ініціативах у сфері охорони здоров'я. Аналізуючи епідеміологічні дані, ШІ може визначати тенденції та фактори ризику в громадах, дозволяючи постачальникам медичних послуг і політикам впроваджувати цільові профілактичні заходи. Це особливо важливо для боротьби зі спалахами інфекційних захворювань, коли раннє виявлення випадків і прогнозне моделювання можуть допомогти стримати поширення та запобігти більш масштабним кризам у сфері громадського здоров'я.

Виділивши основні переваги, також хочу зазначити про три основних недоліки використання штучного інтелекту в медицині. Адже є деякі питання, в яких штучний інтелект не спроможний повністю точно дати відповідь чи зробити аналіз без помилок так, як це робить медичний спеціаліст, який має великий багатий досвід та може побачити всі нюанси.

#### 1. Конфіденційність та безпека.

Проблеми конфіденційності та безпеки є серйозними проблемами при застосуванні штучного інтелекту у медицині. ШІ в охороні здоров'я часто покладається на величезну кількість особистих і конфіденційних даних про особисте здоров'я, які потрібні системам ШІ для ефективного функціонування. Ці дані можуть включати історії хвороби, генетичну інформацію, діагностичні зображення та інші персональні ідентифікатори. Це робить системи вразливими до витоку даних, коли приватна інформація пацієнтів може бути розкрита або використана не за призначенням. Забезпечення захисту даних є складним і дорогим завданням, яке має значні етичні наслідки, якщо нею керувати належним чином.

Моделі штучного інтелекту в охороні здоров'я часто вимагають великих складних наборів даних, включаючи електронні записи про стан здоров'я, дані зображень, результати лабораторних досліджень і генетичну інформацію. Захист цих даних від несанкціонованого доступу стає складним через уразливість передачі даних: програми ШІ в охороні здоров'я можуть покладатися на обмін даними між лікарнями, лабораторіями та хмарними службами. Кожна передача даних збільшує ризик перехоплення, якщо вони не зашифровані належним чином і не захищені.

Уразливості сторонніх розробників: багато систем штучного інтелекту в галузі охорони здоров'я розроблено сторонніми постачальниками, які можуть не мати всеосяжних протоколів безпеки даних або можуть зіткнутися з труднощами при їх послідовному застосуванні в усіх закладах охорони здоров'я. Це може відкрити двері для несанкціонованого доступу, особливо якщо сторонні постачальники не відповідають суворим стандартам безпеки.

Хоча деідентифікація є звичайною практикою для захисту конфіденційності пацієнтів, вона не гарантує анонімності. Алгоритми штучного інтелекту набули досвіду в аналізі шаблонів даних, що іноді дозволяє їм повторно ідентифікувати людей, об'єднуючи анонімні набори даних. Наприклад: перехресне посилання на загальнодоступні дані: навіть деідентифіковані медичні дані іноді можна порівняти з іншими загальнодоступними наборами даних (наприклад, соціальними мережами чи публічними записами), щоб ідентифікувати осіб, особливо у випадках, коли йдеться про рідкісні захворювання чи стани. Медичні зображення та геномна інформація мають унікальну ідентифікацію за своєю природою. Наприклад, генетичний профіль можна відстежити до особи, навіть якщо видалити такі ідентифікатори, як ім'я та дата народження.

Багатьом організаціям охорони здоров'я не вистачає централізованої системи керування даними, яка б гарантувала, що використання ШІ відповідає місцевим і міжнародним нормам. Це може наражати постачальників медичних послуг на юридичну відповідальність і штрафи.

Іншою важливою проблемою є «чорна скринька» багатьох алгоритмів штучного інтелекту, які часто є складними та їх важко інтерпретувати. Для пацієнтів і постачальників ця відсутність прозорості може призвести до дискомфорту та недовіри. Пацієнти та навіть медичні працівники можуть не розуміти, як штучний інтелект дійшов своїх висновків. Без можливості пояснення пацієнти можуть не погоджуватися на лікування чи діагностику, які покладаються виключно на ШІ. Рішення, керовані штучним інтелектом, можуть мати кардинальні наслідки. Важливо, щоб організації охорони здоров'я могли перевіряти системи ШІ, щоб зрозуміти, як приймалися рішення. Однак відсутність чіткого контрольного сліду може ускладнити визначення джерела помилки або перевірку того, що модель AI функціонує правильно.

Щодо етичних міркування мають вирішальне значення для забезпечення відповідального використання ШІ в охороні здоров'я. Етичні проблеми включають інформовану згоду, де пацієнти повинні бути повністю поінформовані про те, як їхні дані використовуватимуться в додатках ШІ. Деякі стверджують, що традиційні форми згоди не охоплюють складні способи обробки даних у штучному інтелекті, що викликає занепокоєння щодо справжньої згоди. Також сюди можна додати проблеми з дотриманням нормативних вимог у різних юрисдикціях. У різних країнах діють власні закони про захист даних, що створює проблеми для систем ШІ, які використовуються за кордоном:

GDPR у Європі: Загальний регламент захисту даних (GDPR) містить суворі вказівки щодо того, як можна збирати, обробляти та зберігати персональні дані. Він наказує мінімізувати дані, коли потрібно збирати лише необхідні дані, а особи мають право на видалення своїх даних («право бути забутих»). [7]

HIPAA (Health Insurance Portability and Accountability Act) у США: Закон про мобільність та відповідальність у медичному страхуванні (HIPAA) включає власний набір правил конфіденційності та безпеки, спрямованих на

обробку медичної інформації. Хоча НІРАА всеосяжний, спочатку не розроблявся з урахуванням штучного інтелекту, що призвело до прогалин у тому, як додатки штучного інтелекту керують і захищають дані охорони здоров'я.

## 2. Втрата людського дотику

«Втрата людського зв'язку» в охороні здоров'я, що керується штучним інтелектом, викликає серйозне занепокоєння, оскільки системам штучного інтелекту часто не вистачає співпереживання, розуміння та особистої взаємодії, які життєво важливі в медичних установах.

Системи штучного інтелекту, як чат-боти та віртуальні помічники, все частіше використовуються для початкової оцінки, сортування та навіть подальшого лікування. Хоча це може підвищити ефективність, це також може зменшити кількість прямої взаємодії між пацієнтами та постачальниками медичних послуг, що може мати важливі наслідки. Пацієнти цінують емпатію в медичних закладах, де часто обговорюються делікатні теми, такі як хронічні захворювання, психічне здоров'я чи догляд за померлими. Лікарі-люди можуть виявляти співчуття через тон, мову тіла та слова заспокоєння, чого наразі не вистачає системам штучного інтелекту, якими б розвиненими вони не були.

Системи штучного інтелекту насамперед навчені розпізнавати шаблони в даних, але можуть не мати можливості повністю зрозуміти особистий контекст пацієнта, його сімейну історію чи унікальне культурне походження. Проте людина, що надає послуги, може включити цей особистий контекст у свій підхід до догляду, покращуючи результати та задоволеність пацієнтів.

Довіра є основою охорони здоров'я, і відсутність людської взаємодії може підірвати цю довіру. Багатьом пацієнтам зручніше обговорювати певні теми, такі як психічне здоров'я, вживання психоактивних речовин або сексуальне здоров'я, з людиною, а не з машиною, що спричиняє небажання ділитися конфіденційною інформацією. Пацієнти можуть вагатися щодо

повної відкритості систем штучного інтелекту, що впливає на точність наданої інформації та, як наслідок, на якість медичної допомоги. Також пацієнти, які вважають, що медична допомога є надто знеособленою або автоматизованою, можуть сприймати її як нижчу якість. Таке сприйняття може призвести до невдоволення, зниження прихильності до рекомендацій щодо лікування та навіть повного небажання звертатися за допомогою.

Людський дотик у сфері охорони здоров'я особливо важливий для цілісного догляду, який враховує не лише фізичні симптоми, але й емоційне, соціальне та психологічне благополуччя. Психічна та емоційна підтримка є однією з важливих складових відносин між лікарем та пацієнтом, які проходять серйозне лікування, наприклад, хіміотерапію, часто отримують користь від заохочення, заспокоєння та психологічної підтримки своїх постачальників медичних послуг. III, зосереджений головним чином на аналізі даних і діагностиці, наразі не має нюансів, щоб надавати емоційну підтримку, адаптовану до індивідуальних потреб. Лікарі-люди часто використовують інтуїцію, розвинену в результаті багаторічного досвіду та навчання, щоб приймати обґрунтовані рішення, особливо в складних або неоднозначних випадках. Ця інтуїція може скерувати їх поставити додаткові запитання або розглянути фактори, які можуть бути неочевидними лише з даних. Системи штучного інтелекту ще не в змозі відтворити цей рівень інтуїції, що потенційно може вплинути на якість догляду в окремих випадках.

### 3. Упередженість у системах штучного інтелекту

Третім недоліком використання штучного інтелекту в медицині є ризик упередженого прийняття рішень що становить значний ризик у галузі медицини, де точне й чесне прийняття рішень має важливе значення для результатів лікування пацієнтів. Упередженість у штучному інтелекті стає все більш важливою проблемою в медицині, де її наслідки можуть безпосередньо вплинути на результати пацієнтів.

Системи штучного інтелекту часто навчаються на історичних даних, вони схильні успадковувати будь-які упередження, присутні в цих даних.

Наприклад, якщо минулі медичні дані відображають відмінності в доступі до медичної допомоги, моделях лікування або діагнозах у різних демографічних групах, моделі штучного інтелекту, навчені на цих даних, можуть посилити цю нерівність. Також можуть містити наявні упередження на основі раси, статі, соціально-економічного статусу чи географічного розташування. Коли ці упередження вбудовані в медичні алгоритми, вони можуть призвести до неоднакових рекомендацій щодо лікування або діагностичних неточностей для певних груп, що зрештою вплине на якість медичної допомоги та сприятиме розбіжностям у здоров'ї. Це суттєво може вплинути на різні аспекти медичної допомог. Зростаюча кількість літератури досліджує причини, прояви та наслідки упередженості ШІ в медицині, висвітлюючи як проблеми, так і можливі рішення.

Відповідно до літератури, расові, гендерні та соціально-економічні упередження історично впливали на доступ до медичної допомоги, види призначеного лікування та якість отриманої медичної допомоги. Моделі штучного інтелекту, навчені на таких даних, можуть успадкувати ці упередження, що призведе до рекомендацій, які посилюють диспропорції, а не пом'якшують їх. Наприклад, у дослідженні Rajkomar, було виявлено, що алгоритми охорони здоров'я, які використовуються для визначення пріоритетності пацієнтів для надання високоінтенсивної медичної допомоги, надають перевагу білим пацієнтам перед чорношкірими через показники, засновані на вартості, які недооцінюють потреби охорони здоров'я в маргіналізованих групах. [8]

Упередженість у медичному штучному інтелекті може призвести до розбіжностей у діагностиці та рекомендаціях щодо лікування, як задокументовано в багатьох дослідженнях. Наприклад, Адамсон і Сміт досліджували системи діагностичного штучного інтелекту, які використовуються в дерматології, і виявили, що багато з них в основному навчалися на зображеннях світліших тонів шкіри. Відсутність різноманітності в навчальних даних призвела до неточностей під час

діагностики шкірних захворювань у пацієнтів із темнішою шкірою, ілюструючи, як діагностичний штучний інтелект може працювати нерівномірно, якщо не навчатися на комплексних наборах даних.[9]

Як висновок до цього розділу можна сказати, що інтеграція штучного інтелекту у медицині є трансформаційним у тому, як надається охорона здоров'я, обіцяючи значні переваги, водночас створюючи значні проблеми. З одного боку, швидкість, ефективність і підвищена точність ШІ переосмислили процеси діагностики та лікування. Його здатність швидко й ефективно аналізувати величезні обсяги даних дає змогу ранньо виявляти захворювання, часто на стадіях, коли діагностика людини може бути невдалою. Крім того, штучний інтелект сприяє зміні парадигми від реактивної охорони здоров'я до проактивного управління охороною здоров'я, надаючи можливість людям і медичним працівникам зосередитися на профілактиці, а не на лікуванні. Ця еволюція не тільки покращує результати лікування пацієнтів, але й зменшує довгострокові витрати, пов'язані з хронічними захворюваннями та втручанням на пізніх стадіях.

Однак ці переваги слід порівнювати з потенційними недоліками, які супроводжують впровадження ШІ. Конфіденційність і безпека залишаються актуальними проблемами, оскільки системи ШІ значною мірою покладаються на конфіденційні особисті дані. Порушення або неправильне використання цієї інформації може підірвати довіру пацієнтів і поставити під загрозу дотримання правил захисту даних. Крім того, використання штучного інтелекту створює ризик зменшення «людського дотику» в медичній допомозі, що часто є критичним для задоволеності пацієнтів та емоційної підтримки. Нездатність систем штучного інтелекту відтворювати емпатію чи тонке спілкування може призвести до того, що пацієнти почуватимуться ізольованими чи не зрозумілими. Нарешті, наявність упереджень в алгоритмах штучного інтелекту, що виникають через помилкові або неповні навчальні дані, може призвести до несправедливих результатів, непропорційно впливаючи на певні демографічні показники та

потенційно закріплюючи диспропорції в охороні здоров'я.

Підсумовуючи, хоча штучний інтелект має потенціал для революції в медицині шляхом підвищення ефективності, точності та профілактичного лікування, його впровадження вимагає збалансованого підходу. Заклади охорони здоров'я зобов'язані надавати пріоритет надійним заходам безпеки даних, підтримувати людський фактор у взаємодії з пацієнтами та активно працювати над пом'якшенням упереджень у системах ІІІ. Її успіх залежить від продуманої інтеграції, постійного нагляду та відданості пріоритету догляду, орієнтованого на пацієнта. Завчасно вирішуючи ці проблеми, медичне співтовариство може використовувати весь потенціал штучного інтелекту, забезпечуючи етичне, справедливе та орієнтоване на пацієнта лікування. Цей збалансований підхід не тільки максимізує переваги, але й зменшить ризики, прокладаючи шлях для більш розвиненої та інклюзивної екосистеми охорони здоров'я. Зрештою, ІІІ в медицині – це не панацея, а потужний інструмент.

### **1.3 Класифікація зображень для виявлення COVID-19**

COVID-19, викликаний новим коронавірусом SARS-CoV-2, вперше з'явився в Ухані, Китай, наприкінці 2019 року та швидко поширився по всьому світу, що призвело до глобальної пандемії. 23 січня 2020 року лідер Китаю Сі Цзіньпін оголосив про введення карантину в місті Ухань через швидке поширення нового коронавірусу SARS-CoV-2. Це рішення стало важливим попередженням для інших країн, які почали впроваджувати власні протиепідемічні заходи на кордонах та в аеропортах, особливо в державах, що мають спільний кордон із Китаєм. Хвороба переважно вражає дихальну систему, проявляючись такими симптомами, як лихоманка, кашель, втома та задишка. Важкі випадки можуть перерости в пневмонію, гострий респіраторний дистрес-синдром (ГРДС) і навіть смерть, особливо у пацієнтів з основними захворюваннями або ослабленою імунною системою. Швидка

передача COVID-19 спричинила потребу в ефективних діагностичних методах для стримування її поширення. Хоча полімеразна ланцюгова реакція зворотної транскрипції (RT-PCR) залишається золотим стандартом діагностики, її обмеження, такі як тривалий час виконання, залежність від лабораторної інфраструктури та потенційні хибно-негативні результати, спонукали до вивчення альтернативних методів. Медична візуалізація, включаючи рентген грудної клітки (CXR) і комп'ютерну томографію (КТ), стала критичною для виявлення аномалій легень, викликаних COVID-19. Ці методи також виявилися корисними, однак вони не завжди дозволяли на 100% точно визначити наявність COVID-19, оскільки характерні зміни на знімках могли бути схожими на зміни, що супроводжують інші респіраторні захворювання. Пневмонія, наприклад, може мати дуже подібні симптоми на рентгені, але бути викликана іншими інфекціями. Це означало, що лікарям доводилось покладатись на свої клінічні навички, а діагноз на основі рентгену чи КТ часто не давав чіткої відповіді.




Рисунок 1.1 - Вигляд вірусу COVID-19

З появою пандемії виявлення COVID-19 за допомогою зображень стало однією з ключових тем досліджень у галузі штучного інтелекту. Завдяки використанню методів глибокого навчання, таких як згорткові нейронні мережі, ШІ зміг допомогти в розпізнаванні характерних ознак COVID-19 на

рентгенівських знімках і КТ, полегшуючи роботу лікарів і підвищуючи точність діагностики.

Класифікація зображень у випадку виявлення COVID-19 – це процес автоматичного визначення на основі медичних зображень (наприклад, рентгенографії або комп'ютерної томографії), чи є ознаки захворювання у пацієнта.




Рисунок 1.2 – Приклад класифікація рентгенівських знімків за допомогою ШІ для виявлення COVID-19




Рисунок 1.3 – Приклад класифікація КТ-знімків за допомогою ШІ для виявлення COVID-19

Класифікація зображень, важливе застосування штучного інтелекту в комп'ютерному зорі, передбачає автоматичне розподілення зображень за

попередньо визначеними класами шляхом виділення та аналізу візуальних характеристик. У виявленні COVID-19 алгоритми штучного інтелекту, зокрема згорткові нейронні мережі (CNN), продемонстрували виняткову здатність аналізувати рентгенографічні візерунки, які можуть бути не відразу помітні радіологам. Модель, натренована на великій кількості знімків із чіткими мітками, наприклад: "норма", "пневмонія", "COVID-19"; здатна визначити до якого класу належить новий знімок.



Рисунок 1. 4 – Рентгенівський знімок легень здорової людини



Рисунок 1.5 - Рентгенівський знімок легень з COVID-19



Рисунок 1.6 – Рентгенівський знімок легень з пневмонією

Спочатку, ШІ у виявленні коронавірусної хвороби допоміг тим, що забезпечив швидке оброблення великих обсягів медичних зображень, що дозволяло лікарям за короткий час отримати попередню оцінку стану пацієнта. Ці моделі навчаються на великих наборах даних із позначеними медичними зображеннями, які проходять етапи попередньої обробки, такі як нормалізація, зміна розміру та доповнення для покращення різноманітності даних і надійності моделі. Особливо важливою перевагою ШІ було те, що він міг аналізувати зображення в реальному часі. Це дозволяло лікарям швидко отримувати допомогу в прийнятті рішення щодо діагностики і лікування, що було критично важливо, оскільки COVID-19 може швидко прогресувати, і пацієнти потребують термінової медичної допомоги. Класифікація зображень у контексті COVID-19 стає дедалі ширшою і більш функціональною завдяки постійному розвитку алгоритмів штучного інтелекту. Одним із нових напрямків є використання багатомодальних підходів, де класифікація зображень поєднується з аналізом інших типів медичних даних, таких як аудіозаписи дихання, результати ПЛР-тестів або навіть дані з пульсоксиметрів. Такий підхід дозволяє створювати більш надійні моделі, які не лише діагностують COVID-19, але й визначають стадію захворювання, ризик ускладнень чи ймовірність госпіталізації.

Ще один цікавий аспект — це адаптація класифікаційних моделей до роботи в умовах різноманітних типів медичного обладнання. Оскільки у світі використовується широкий спектр рентгенівських і КТ-сканерів із різною якістю зображень, новітні моделі ШІ стали здатними працювати з неоднорідними даними. Цього досягають за рахунок використання технологій нормалізації, які вирівнюють якість зображень, або ж моделей, стійких до варіацій у даних.

Підкріплювальне навчання (Reinforcement Learning) – інноваційний підхід, який здатний самостійно оптимізувати процес аналізу зображень. Наприклад, така модель може визначати найбільш інформативні області на рентгенівському знімку, зосереджуючи аналіз саме на них, що підвищує ефективність діагностики.

Крім того, важливим напрямком стало навчання моделей на основі відкритих баз даних із різних країн. Це дозволяє створювати системи, які враховують демографічні й етнічні особливості пацієнтів, адже COVID-19 може по-різному впливати на людей залежно від віку, статі чи наявності хронічних захворювань.

Значна увага приділяється також розробці "легковагих" моделей, які можуть працювати на мобільних пристроях чи у віддалених лікарнях із обмеженими обчислювальними ресурсами. Такі моделі забезпечують швидку класифікацію, що особливо важливо для сільських районів або країн із недостатньо розвиненою медичною інфраструктурою.

Таким чином, сучасна класифікація зображень уже не обмежується лише визначенням COVID-19. Вона трансформується у комплексний інструмент для аналізу стану пацієнтів, моніторингу прогресу хвороби та підтримки прийняття клінічних рішень. Це демонструє, як глибокі технології штучного інтелекту можуть розв'язувати реальні медичні проблеми й робити діагностику доступною, точною і швидкою навіть у найскладніших умовах.

У процесі класифікації зображень ключову роль відіграє мультикласова класифікація та точкове виявлення уражених ділянок. Ця

класифікація використовується для диференціації COVID-19, бактеріальної пневмонії, вірусної пневмонії та здорових легень на основі медичних зображень, таких як рентген або КТ. Цей підхід дозволяє лікарям точніше діагностувати захворювання і уникати плутанини між різними типами уражень легенів.

Використовуючи алгоритми глибокого навчання, такі як ResNet, EfficientNet або DenseNet, система аналізує структури тканин і виявляє характерні патерни. Це особливо корисно для диференціювання захворювань, які мають схожі клінічні прояви, але потребують різного підходу до лікування. Завдяки сучасним алгоритмам машинного навчання досягається висока точність і швидкість обробки зображень, що особливо важливо у разі масового скринінгу. [10]

Точкове виявлення уражених ділянок у легенях є невід'ємною складовою діагностики COVID-19 на основі зображень. Цей метод ґрунтується на сегментації областей ураження з високою деталізацією, що дозволяє визначити обсяги запалення, оцінити ступінь тяжкості захворювання та моніторити динаміку його перебігу. Зокрема, моделі сегментації здатні виділяти зони "матового скла", консолідації та інші патологічні зміни, характерні для COVID-19. Зазвичай використовуються архітектури на основі U-Net, Mask R-CNN або Deeplab, що здатні детально окреслити уражені області. Локалізація дозволяє вимірювати об'єм і поширення уражень, оцінювати динаміку змін і прогнозувати результати лікування. Також сегментація може допомагати визначати ступінь ураження органів, що використовується для класифікації пацієнтів за тяжкістю стану.

Одним із новітніх підходів є використання безрозміткових методів сегментації, які дозволяють обходити проблему дефіциту розмічених даних. Наприклад, модель NormNet використовує аномальні патерни, синтетично додані до нормальних зображень, для навчання. Це значно розширює можливості діагностики в умовах пандемії, коли розмічення зображень є ресурсозатратним процесом. Таким чином, точкове виявлення уражених

ділянок не лише забезпечує високу точність аналізу, але й надає лікарям критично важливу інформацію для прийняття обґрунтованих рішень. Розвиток цього напрямку сприяє підвищенню ефективності медичної допомоги, особливо у періоди криз, таких як пандемія COVID-19. [11]

Отже, як висновок можна зазначити, що класифікація зображень стала важливим інструментом у боротьбі з COVID-19, швидку і точну діагностику. Штучний інтелект дає змогу автоматично аналізувати медичні зображення, виявляти характерні ураження легенів і розрізняти різні захворювання, такі як COVID-19, пневмонії та здорові легені. Це не лише підвищує ефективність діагностики, але й зменшує навантаження на медичний персонал. Поєднання класифікації та сегментації створює комплексний підхід, що покращує моніторинг захворювання, персоналізацію лікування та доступність медичної допомоги в умовах пандемії. Ці інновації не тільки вдосконалюють клінічні робочі процеси, але й вирішують проблеми в умовах обмежених ресурсів, демонструючи критичну роль штучного інтелекту у реагуванні на глобальні кризи в галузі охорони здоров'я.

## **РОЗДІЛ 2. ПОПЕРЕДНЬО НАВЧЕНІ МОДЕЛІ ДЛЯ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ**

### **2.1 Огляд глибоких нейронних мереж для класифікації зображень**

Згорткові глибокі нейронні мережі стали важливим інструментом у сучасних технологіях обробки даних, демонструючи вражаючі результати в різних сферах, включаючи комп'ютерний зір, обробку тексту та мови, а також медичну діагностику. Їхня здатність навчатися складним залежностям та витягувати приховані особливості з великих обсягів даних зробила ці моделі особливо корисними в задачах, де традиційні методи машинного навчання мають обмеження. Одним із найважливіших напрямків їх застосування є класифікація медичних зображень, що дозволяє автоматизувати діагностику захворювань, зменшити кількість помилок і

підвищити точність діагнозу.

Пандемія COVID-19 підкреслила важливість швидкої та точної діагностики, особливо з використанням рентгенографії та комп'ютерної томографії (КТ). У цьому контексті глибокі нейронні мережі забезпечили інноваційні підходи до аналізу медичних зображень, допомагаючи виявляти специфічні ознаки ураження легень, викликані вірусом. Для задачі виявлення COVID-19 були адаптовані та розроблені різні архітектури нейронних мереж, які відрізняються за своїм підходом до обробки зображень, здатні адаптуватися до специфічних особливостей медичних даних. Наприклад, деякі з них орієнтовані на обробку зображень низької якості (часто характерних для рентгенівських знімків), тоді як інші оптимізовані для роботи з багатовимірними даними, такими як КТ або МРТ. Такі мережі часто навчаються із застосуванням технік попереднього навчання, використовуючи великі відкриті набори даних (наприклад, ImageNet), після чого вони донавчаються на спеціалізованих медичних наборах.

Однак розробка таких моделей стикається з численними викликами. Одним із основних є обмежений доступ до якісних та збалансованих медичних наборів даних через проблеми конфіденційності та недостатню кількість випадків для рідкісних захворювань. Крім того, медичні дані часто мають велику варіативність у якості та форматах, що ускладнює створення універсальних моделей.

У цьому розділі ми детально розглянемо ключові архітектури згорткових нейронних мереж, які застосовуються для класифікації медичних зображень. Особливий акцент буде зроблено на їх використанні для діагностики COVID-19, включаючи базові згорткові нейронні мережі (CNN), глибокі моделі з резидуальними блоками (ResNet), щільні мережі (DenseNet), а також новітні трансформери (Vision Transformers). Ми також аналізуватимемо, як ці моделі адаптуються до специфіки медичних даних і які переваги вони надають для боротьби з пандемією.

Першою на огляду буде згорткова нейронна мережа – основа сучасної обробки зображень і широко використовується для класифікації медичних знімків і задачі комп'ютерного зору.




Рисунок 2.1 – Вигляд архітектури CNN

Більшість властивостей згорткових нейронних мереж порівнюють із звичайним штучними нейронними мережами, проте ЗНМ в основному використовують для ідентифікації моделей у зображеннях. Згорткові нейронні мережі можна розподілити на так рівні:

**Вхідний рівень (Input Layer).** Цей рівень надає можливість комп'ютеру читати зображення, що являються пікселями, які потім, можливо, доведеться нормалізувати, тобто, підготувати для подальшої обробки. Сюди входять як зображення, так і аудіо сигнали чи інші форми даних.

**Згортковий рівень.** Це рівень у згорткових нейронних мережах є ключовим елементом, який відповідає за витягування локальних ознак із вхідних даних, таких як текстури, краї та форми. Цей рівень працює за допомогою фільтрів або ядер згортки, які є малими матрицями, що застосовуються до зображення за допомогою операції згортки. Зазвичай воно у вигляді матриці  $3 \times 3$ , або  $5 \times 5$ , що застосовуються до вхідного

зображення шляхом згортки. Скалярний добуток між вхідними пікселями та екстрактором ознак обчислюється після застосування фільтра до певної ділянки зображення. Результируюче значення записується у вихідний масив. Екстрактор ознак переміщається по пікселях вхідного шару, і цей процес триває до повної обробки зображення.

Скалярний добуток — це математична операція між двома векторами, результатом якої є скалярне значення (число). Для двох векторів

$$\vec{A} = (a_1, a_2, \dots, a_n)$$

$$\text{та } \vec{B} = (b_1, b_2, \dots, b_n)$$

скалярний добуток обчислюється за формулою:

$$\vec{A} \cdot \vec{B} = a_1 \cdot b_1 + a_2 \cdot b_2 + \dots + a_n \cdot b_n$$

Результатом цієї операції є так звані карти ознак, які містять інформацію про присутність певних ознак в різних частинах зображення. Крім того, для контролю над розмірами карти ознак використовуються параметри кроку (stride) та заповнення (padding), що визначають, на скільки пікселів фільтр пересувається і як обробляються краї зображення. Після виконання згортки зазвичай застосовується функція активації, така як ReLU, яка додає нелінійність і дозволяє мережі вивчати складніші ознаки. Згортковий рівень забезпечує локальність, оскільки фільтри працюють лише з невеликими ділянками зображення, та сумісність ваг, оскільки той самий фільтр використовується для всієї картки. Завдяки цьому можна ефективно виявляти та аналізувати важливі ознаки в даних, що значно знижує кількість параметрів та робить модель більш ефективною.

Третій рівень - Рівень класифікації (Fully Connected Layer). Цей рівень є переходом від просторових ознак, виділених попередніми згортковими

шарами, до абстрактного представлення, яке може бути використане для класифікації або інших завдань. Він складається з одного або кількох повнозв'язаних шарів, де кожен нейрон пов'язаний з усіма нейронами попереднього шару. На цьому етапі модель об'єднує локальні ознаки в єдине представлення, що містить глобальну інформацію про весь об'єкт. Щоб перейти від багатовимірної карти ознак до плоского вектора, застосовується операція розгортання, після чого дані проходять через повнозв'язані шари.

На рівні класифікації часто використовуються різні функції активації. Для проміжних шарів зазвичай застосовується ReLU (Rectified Linear Unit), яка додає нелінійність і дозволяє моделі розпізнавати складніші залежності між ознаками.

Важливою характеристикою повнозв'язного шару є те, що він має велику кількість параметрів, зокрема ваг і зсувів, які підлаштовуються під навчальні дані. Ваги визначають важливість кожної ознаки в процесі класифікації, а зсуви дозволяють зберігати певну гнучкість у функціонуванні моделі. Кожен нейрон у цьому шарі обчислює зважену суму всіх вхідних сигналів і застосовує активаційну функцію для отримання результату. Зазвичай на цьому етапі використовуються такі функції активації, як Softmax, для багатокласової класифікації, що дає змогу нормалізувати вихідні значення до ймовірностей, які в сукупності складають 1. Це дозволяє системі однозначно визначити, до якого класу має належати об'єкт на основі оброблених даних. В іншому випадку для двокласової класифікації може застосовуватися функція Sigmoid, яка видає значення між 0 та 1, що інтерпретується як ймовірність приналежності до позитивного класу.

Основна роль рівня класифікації — об'єднати всі ознаки, які були знайдені під час роботи згорткових і підвибіркових шарів, у єдине висновок, що є узагальненим представленням даних. Завдяки цьому рівень класифікації визначає, як мережа приймає остаточні рішення, і забезпечує її здатність розпізнавати складні залежності у вхідних даних.

Вихідний рівень (Output Layer) у згортковій нейронній мережі — це

заключний шар мережі, який забезпечує формування результату її роботи. Цей шар приймає на вхід вектори ознак, оброблені попередніми шарами, і виконує завдання класифікації, регресії або іншого типу прогнозування залежно від поставленої задачі. Зазвичай цей рівень складається з одного або кількох повнозв'язних шарів (fully connected layers), що підсумовують інформацію, що пройшла через мережу, і передають її у вигляді остаточних прогнозів. Наприклад, в задачах класифікації, вихідний рівень може мати стільки нейронів, скільки класів потрібно класифікувати, і використовувати функцію активації softmax для отримання ймовірностей для кожного класу. Цей рівень є завершальним етапом обробки в нейронній мережі, забезпечуючи необхідний результат, оснований на ознаках, виділених на попередніх етапах.

Наступним на черзі в огляді буде ResNet(Residual Networks) – один із на успішніших типів глибоких нейронних мереж, який значно покращив точність класифікації зображень завдяки впровадженню резидуальних блоків. Основна ідея ResNet полягає в подоланні проблеми згасання градієнтів, яка виникає при тренуванні дуже глибоких мереж. Резидуальні блоки дозволяють передавати інформацію через шари мережі за допомогою механізму "коротких з'єднань" (skip connections), що забезпечує більш стабільне навчання та підвищує продуктивність навіть для надзвичайно глибоких моделей.

Для задач класифікації медичних зображень, зокрема діагностики COVID-19,

ResNet є одним із найпопулярніших підходів завдяки своїй здатності виявляти складні патерни у великих наборах даних. Різні варіації ResNet, такі як ResNet-18, ResNet-50 і ResNet-101, застосовуються для аналізу рентгенограм легень та комп'ютерної томографії. Завдяки резидуальним блокам ці моделі зберігають високий рівень точності навіть за наявності значного рівня шуму або артефактів у медичних зображеннях.

Крім основних переваг, таких як здатність до навчання глибоких

моделей і ефективно подолання проблеми згасання градієнтів, ResNet також має кілька цікавих аспектів, які роблять її ще більш привабливою для використання в медичних додатках. Однією з таких особливостей є здатність ResNet до "простого" навчання, що дозволяє моделі додавати нові шари без погіршення якості роботи мережі. В інших типах нейронних мереж збільшення кількості шарів може призводити до значного зниження ефективності через проблему згасання градієнтів, в той час як в ResNet це зменшується завдяки механізму пропуску градієнтів через резидуальні блоки. Це дозволяє створювати мережі з величезною кількістю параметрів, які здатні моделювати складні структури в зображеннях, що є важливим для медичних зображень, де навіть дрібні деталі можуть мати вирішальне значення для правильного діагнозу.

Одним із головних прикладів використання ResNet для виявлення COVID-19 є адаптація попередньо натренованих моделей, які донавчаються на спеціалізованих медичних наборах даних. Наприклад, моделі ResNet-50, треновані на ImageNet, часто використовуються як базові мережі, після чого їх донавчають на рентгенограмах легень для виявлення специфічних патологій, таких як "матове скло" або пневмонія, характерна для COVID-19. Ключовою перевагою ResNet є її здатність до узагальнення: завдяки глибині і структурі, модель може враховувати як локальні, так і глобальні особливості зображення. Це особливо важливо для медичних задач, де патерни можуть бути дрібними, розмитими або нерівномірно розподіленими по зображенню.

Крім того, ResNet добре масштабується для різних типів даних. Наприклад, у випадку КТ модель може адаптуватися для аналізу тривимірних зображень шляхом модифікації стандартних 2D-конволюцій до 3D-варіантів. Це дозволяє використовувати ResNet для аналізу не лише окремих зрізів, але й цілого об'єму зображень, що значно підвищує її ефективність у виявленні COVID-19. Однак є й певні виклики. Моделі ResNet вимагають великої обчислювальної потужності для тренування, що

може бути обмеженням у випадках, коли доступні ресурси недостатні. Крім того, для ефективного навчання на медичних зображеннях потрібні великі збалансовані набори даних, що не завжди доступно через конфіденційність та етичні питання.

Також ResNet використовується для пояснювальної діагностики (*explainable AI*). Інтеграція з методами візуалізації, такими як Grad-CAM, дозволяє створювати теплові карти, які показують, на які саме області зображення модель звертає увагу під час діагностики COVID-19. (Рис) Це дає лікарям можливість верифікувати висновки моделі та забезпечує прозорість роботи алгоритму.




Рисунок 2.2 – Діагностика Covid-19 з методом Grad-CAM ResNet –  
вихідне положення




Рисунок 2.3 – Діагностика Covid-19 з методом Grad-CAM ResNet –  
Grad-CAM

Таким чином, ResNet є одним із найбільш перспективних підходів для класифікації медичних зображень, включаючи виявлення COVID-19, яка здійснила революцію в аналізі зображень завдяки використанню резидуальних блоків. Її здатність долати проблему згасання градієнтів і підтримувати стабільне навчання навіть у надглибоких мережах зробила ResNet невід'ємною частиною сучасних рішень для комп'ютерного зору. Її здатність долати складні виклики, пов'язані з аналізом зображень, робить цю архітектуру ключовим компонентом у сучасних системах автоматизованої діагностики.

DenseNet (Dense Convolutional Network). ще однією важливою архітектурою глибокого навчання, яка здобула значну популярність завдяки ефективності та інноваційному підходу до побудови нейронних мереж. Головною особливістю DenseNet є використання "щільних з'єднань", які забезпечують прямий зв'язок між усіма шарами мережі. Це означає, що кожен шар отримує інформацію з виходів усіх попередніх шарів і передає свої власні результати до всіх наступних шарів. Такий підхід сприяє максимальному повторному використанню функцій, зменшує надмірність у параметрах і покращує поширення градієнтів під час навчання. DenseNet є особливо ефективною для задач класифікації зображень, оскільки її архітектура дозволяє виділяти як низькорівневі, так і високорівневі особливості без втрати значущої інформації. Завдяки цьому модель демонструє високу точність навіть при використанні меншої кількості параметрів у порівнянні з іншими сучасними мережами, такими як ResNet. Це робить DenseNet менш ресурсомісткою, що є перевагою для медичних застосувань, де часто обмежені обчислювальні можливості.

У медичних додатках DenseNet часто використовується для аналізу рентгенограм, комп'ютерної томографії (КТ) та магнітно-резонансної томографії (МРТ). У випадку діагностики COVID-19 DenseNet продемонструвала свою здатність ефективно класифікувати медичні зображення на класи, такі як "норма", "пневмонія" і "COVID-19".

Важливим аспектом є її здатність працювати з невеликими наборами даних, що досягається через використання перенавчання та технік розширення даних (data augmentation). Наприклад, DenseNet може бути попередньо навчена на великій загальній базі зображень, а потім адаптована для специфічних медичних завдань.

Крім того, DenseNet добре підходить для роботи з задачами сегментації зображень, які є важливими для локалізації патологічних областей. Використання "щільних" з'єднань забезпечує кращу деталізацію та роздільну здатність виявлення областей ураження, таких як "матове скло" в легенях при COVID-19. Ця архітектура також інтегрується з методами пояснювального штучного інтелекту, такими як Grad-CAM, дозволяючи створювати теплові карти, які підсвічують найбільш значущі області зображення для діагностики.




Рисунок 2.3 - Діагностика Covid-19 з методом Grad-CAM DenseNet –  
вихідне положення




Рисунок 2.4 - Діагностика Covid-19 з методом Grad-CAM DenseNet – Grad-CAM

Важливим доповненням є те, що DenseNet забезпечує хорошу узагальнюваність завдяки високій ефективності використання параметрів. Це означає, що модель може ефективно навчатися навіть на високошумових або обмежених наборах даних, що є поширеною проблемою у медичних задачах. Водночас вона підтримує баланс між точністю і швидкістю, що є критично важливим для реального застосування в умовах лікарень чи лабораторій.

Використання цього методу показує свою перевагу, коли кількість даних дуже незбалансована, а знання, отримані за допомогою іншого завдання (класифікація пневмонії чи непневмонії), можуть сприяти кращому використанню. По-друге, останній рівень попередньо навченої моделі DenseNet змінюється на повністю підключений рівень із класифікатором трьох нейронів для завдання класифікації трьох класів (COVID-19, пневмонія та норма). Модифікована модель DenseNet навчена наборами даних, які включають 6432 унікальних рентгенівських зображення. На етапі тестування навчена модель DenseNet використовується для виявлення

рентгенівських зображень. [12]

Отже, DenseNet є потужною архітектурою глибокого навчання, що значно покращує точність медичної діагностики, зокрема виявлення COVID-19 на рентгенограмах та КТ. Завдяки щільним з'єднанням між шарами, вона ефективно використовує доступну інформацію, що дозволяє досягти високої продуктивності навіть при обмежених наборах даних. Її здатність працювати з великими обсягами зображень та враховувати малопомітні деталі робить DenseNet важливим інструментом для автоматизованої діагностики в медичних системах.

4. Vision Transformer (ViT) — це модель глибокого навчання, яка адаптує

архітектуру трансформера, спочатку створену для обробки природної мови (NLP), для застосування в задачах комп'ютерного зору. Vision Transformer базується на архітектурі трансформатора, спочатку представлений Васвані та ін. у 2017 році для завдань НЛП. [13]

На відміну від звичайних згорткових нейронних мереж, які обробляють зображення через локальні сприйнятливі поля, ViT розглядає зображення як послідовності патчів, подібно до того, як трансформатори обробляють послідовності слів у завданнях НЛП. У ViT зображення ділиться на частини, які не перекриваються, і кожна частина згортається у вектор. Потім ці вектори лінійно вбудовуються в послідовність фіксованого розміру, яка подається в модель трансформатора. Цей підхід дозволяє моделі охоплювати довгострокові залежності та глобальну контекстну інформацію в зображенні, на відміну від CNN, які більше зосереджені на локальних особливостях. Ключовою інновацією ViT є його здатність звертати увагу на глобальні зв'язки в зображенні за допомогою механізмів самоконтролю, що призводить до покращення продуктивності багатьох складних завдань розпізнавання зображень.

Vision Transformers продемонстрували надзвичайну продуктивність у масштабних тестах класифікації зображень, таких як ImageNet,

перевершуючи традиційні CNN під час навчання на великих наборах даних. При навчанні на достатньому обсязі даних ViT перевершує сучасний CNN, маючи приблизно в чотири рази менше обчислювальних ресурсів. [14] Однією з значних переваг є його масштабованість: у міру збільшення розміру моделі та набору даних точність ViT продовжує підвищуватися. Однак зазвичай вимагає великих обсягів позначених даних і обчислювальних ресурсів, особливо на етапі навчання. Дослідники працювали над вирішенням цієї проблеми, вводячи різні методи, такі як гібридні моделі, де CNN використовуються для попередньої обробки зображень перед тим, як їх пропускати через ViT, і застосовуючи попередньо навчені моделі за допомогою трансферного навчання.

У медичних програмах ViT показав перспективу для таких завдань, як виявлення COVID-19, де його можна застосовувати для класифікації рентгенівських знімків грудної клітки та комп'ютерної томографії. Його здатність аналізувати зображення в усьому світі робить його особливо придатним для виявлення складних моделей у медичній візуалізації, таких як ледь помітні ознаки пневмонії чи пошкодження легенів, пов'язаного з COVID-19, які важко визначити традиційними методами. Застосування ViT в медицині не обмежується лише COVID-19. Вони використовуються також у детекції раку, аналізі медичних зображень для діагностики легеневих захворювань, таких як пневмонія, і для моніторингу інших типів патологій. Моделі ViT можуть комбінуватися з іншими підходами для підвищення точності, як, наприклад, використання гібридних архітектур з CNN для попередньої обробки зображень перед передачею їх в трансформери.




Рисунок 2.5 – Приклад класифікації зображень виявлення COVID-19, пневмонія за допомогою ViT

Як висновок до цього розділу, огляд сучасних глибоких нейронних мереж, зокрема згорткових нейронних мереж (CNN), ResNet, DenseNet і Vision Transformers, показує їх важливість і ефективність у класифікації зображень, особливо в медичних застосуваннях. Вони дозволяють автоматизувати процеси виявлення та аналізу зображень, що є надзвичайно важливим для швидкої та точної діагностики захворювань, таких як COVID-19. Кожна з цих архітектур має свої особливості: CNN ефективно працює з локальними ознаками, ResNet вирішує проблему затухаючого градієнта за допомогою залишкових зв'язків, DenseNet покращує обмін інформацією між шарами, а Vision Transformers, завдяки своїй здатності обробляти глобальні залежності, дозволяють досягати високих результатів при класифікації складних медичних зображень.

Ці технології значно покращують точність і швидкість діагностики, що особливо важливо в умовах пандемій і глобальних викликів для охорони здоров'я. Їх здатність працювати з великими наборами даних і враховувати деталі, які можуть бути непомітними для традиційних методів, робить їх

важливими інструментами в медицині, зокрема в автоматизованому аналізі рентгенівських знімків, КТ та інших медичних зображень. Їх комбіноване застосування може суттєво покращити результати в галузі медичних досліджень та практики.

## **2.2 Попередньо навчені моделі: визначення та принцип роботи**

Попередньо навчені моделі, також відомі як "pre-trained models", є однією з ключових складових сучасного машинного навчання, зокрема в таких важливих сферах, як охорона здоров'я, епідеміологія та біомедицина. Вони представляють собою алгоритми, які були навчені на великому обсязі даних і можуть бути адаптовані для вирішення нових задач, часто без необхідності їх повного перенавчання з нуля. Цей підхід особливо ефективний, коли доступ до нових даних є обмеженим, або коли процес навчання потребує значних ресурсів і часу.

У контексті пандемії COVID-19, попередньо навчені моделі стали надзвичайно корисними. Вони дозволили вченим та медичним працівникам оперативно аналізувати величезні масиви даних, що стосуються вірусу, його генетичних особливостей, моделей поширення, а також клінічних аспектів захворювання. Такі моделі забезпечили інструменти для швидкої адаптації до нових викликів, що виникли під час пандемії, допомагаючи в прогнозуванні нових спалахів, розробці вакцин, а також оптимізації лікувальних методів.

Один із основних підходів до навчання попередньо навчених моделей полягає в використанні глибоких нейронних мереж (Deep Learning), які можуть автоматично видобувати необхідні ознаки з сирих даних, таких як зображення, текст або аудіо, і забезпечувати високий рівень точності навіть при невеликій кількості нових даних. Завдяки цьому підходу моделі мають значний потенціал для розв'язання найскладніших завдань, включаючи аналіз молекулярних структур вірусів або виявлення невидимих патернів у великих масивах клінічних записів.

Застосування попередньо навчених моделей у контексті COVID-19 охоплює не лише питання епідеміології, але й сферу лікування та медичних досліджень. Наприклад, такі моделі використовуються для моделювання ефективності різних вакцин, прогнозування їх впливу на різні групи населення, а також для аналізу даних про перебіг хвороби та визначення найкращих методів лікування залежно від особливостей конкретного пацієнта. Крім того, вони активно застосовуються для оптимізації розподілу медичних ресурсів та планування стратегій боротьби з епідемією, що є важливим аспектом у часи, коли система охорони здоров'я знаходиться під великою навантаженням.

Попередньо навчені моделі (*pre-trained models*) — це моделі машинного навчання, які були навчена на великих обсягах даних для виконання загальних завдань або для вирішення конкретних типів задач, таких як класифікація, регресія, або виявлення аномалій. Ці моделі проходять попередній етап навчання на великому наборі даних до того, як їх застосовують до нових, менш оброблених або специфічних наборів даних. Основною їх перевагою є можливість переносу знань, здобутих під час попереднього навчання, для швидкого адаптування до нових умов без необхідності повторного навчання з нуля. Попередньо навчені моделі зазвичай використовуються у завданнях, де є обмеження на кількість доступних даних або ресурсів для навчання, і вони дозволяють підвищити ефективність та точність обчислень, скорочуючи час та обсяг необхідних для навчання ресурсів.

Важливо також зазначити, що попередньо навчені моделі зазвичай навчалися на даних, що охоплюють різні області, і можуть мати певні обмеження щодо специфічності або точності для вузьких завдань. Однак для багатьох загальних задач вони є досить потужним інструментом, який дозволяє ефективно вирішувати проблеми з мінімальними затратами часу та ресурсів.

У результаті застосування попередньо навчених моделей стало

можливим значне пришвидшення наукових досліджень і впровадження нових технологій, а також зниження витрат на розвиток нових алгоритмів, що дає змогу зосередитися на специфічних аспектах проблеми.

В основі попередньо навчених моделей лежить принцип трансферного навчання. Трансферне навчання передбачає використання моделі, яка була навчена для одного завдання, і повторне використання її вивчених параметрів і знань для вирішення нового, але пов'язаного завдання. Це значно зменшує потребу у великих наборах даних для конкретного завдання, дозволяючи моделі досягти високої продуктивності, навіть якщо для нового завдання доступний лише невеликий обсяг даних. По суті, попередньо підготовлені моделі дозволяють передавати знання, отримані з широкого загального контексту, до більш спеціалізованих програм, процес, який імітує те, як люди можуть застосовувати попередні знання в нових ситуаціях. Трансферне навчання дозволяє попередньо підготовленим моделям адаптуватися до нових завдань з мінімальними даними, що особливо корисно в ситуаціях, коли анотованих даних мало або дорого. [15]

Перший етап роботи попередньо навчених моделей — це етап попереднього навчання, коли модель навчається розпізнавати патерни і структури на великій кількості загальних даних. У випадку з COVID-19 це можуть бути великі набори медичних зображень, зокрема рентгенівських знімків легенів, чи текстові дані, що містять опис симптомів і результатів тестів на COVID-19. Моделі, попередньо навчені на цих даних, здатні ефективно ідентифікувати ознаки захворювання, такі як пневмонія, що викликана COVID-19, на основі зображень грудної клітки або результатів аналізів.

Таке навчання часто здійснюється за допомогою глибинних нейронних мереж, зокрема згорткових нейронних мереж для обробки медичних зображень для аналізу текстових даних. Ключовою метою є не просто навчити модель, а й отримати знання, які можна адаптувати до конкретних завдань, таких як визначення важкості перебігу COVID-19 або виявлення

можливих ускладнень у пацієнтів.

Після етапу попереднього навчання, модель використовує перенос навчання для адаптації до конкретних завдань, пов'язаних з COVID-19. Завдяки переносному навчанню можна уникнути необхідності навчання моделі з нуля, що заощаджує значну кількість ресурсів і часу. Наприклад, модель, навчена на великих наборах даних з медичних зображень, може бути адаптована для виявлення специфічних ознак COVID-19 на рентгенівських знімках чи КТ-сканах.

Процес доопрацювання моделі зазвичай включає:

1. Заморожування початкових шарів: На перших етапах навчання мережа може засвоїти загальні патерни, такі як форми і контури на зображеннях, тому ці шари часто заморожуються під час доопрацювання. Це дозволяє зберегти знання, отримані під час попереднього навчання, і скоротити необхідний час для доопрацювання на новому наборі даних.
2. Доопрацювання останніх шарів: Останні шари, що відповідають за специфічні прогнози (наприклад, виявлення COVID-19 у зображеннях), можуть бути налаштовані за допомогою нових даних, таких як знімки легенів пацієнтів з COVID-19. Це дозволяє моделі зосередитися на характеристиках, характерних саме для цього захворювання.
3. Додавання нових шарів: Для більш специфічних завдань можна додавати нові шари, які будуть навчатися з нуля. Наприклад, для задачі прогнозування кількості випадків COVID-19 можна додати нові шари для аналізу епідеміологічних даних.

Поступове навчання є важливим підходом у розробці попередньо навчених моделей, особливо у динамічних умовах, таких як боротьба з COVID-19. Цей метод дозволяє поступово оновлювати модель, додаючи нові знання, без необхідності повного перенавчання. Такий підхід має численні переваги, зокрема економію обчислювальних ресурсів, можливість швидкої

адаптації до змін та збереження раніше отриманих знань. Суть поступового навчання полягає в тому, щоб модель могла інтегрувати нові дані або знання, зберігаючи при цьому ефективність у виконанні завдань, для яких вона була створена раніше. У випадку COVID-19 це може бути додавання нових медичних даних, таких як рентгенівські знімки пацієнтів із мутаціями вірусу, дані про симптоматику, характерну для нових штамів, або оновлену епідеміологічну інформацію про зміну способів поширення вірусу. Поступове навчання дозволяє моделі враховувати ці зміни, не втрачаючи здатності працювати з уже відомими випадками.

Процес поступового навчання розпочинається з вибору нових даних, що відображають змінені умови чи нові завдання. Для COVID-19 це можуть бути актуальні набори знімків, клінічних даних чи епідеміологічних звітів, які дозволяють моделі швидко адаптуватися до змін. Після цього модель аналізує вже існуючі знання, щоб уникнути їхньої втрати під час навчання на нових даних. Збереження таких знань зазвичай забезпечується методами регуляризації, які дозволяють зберегти важливі параметри, відповідальні за виконання попередніх завдань.

Під час навчання модель інтегрує нову інформацію, оновлюючи лише частину своїх параметрів. Найчастіше ті шари, які відповідають за загальні ознаки, залишаються незмінними, тоді як оновлюються лише спеціалізовані шари, що адаптуються до нових характеристик даних. Це дає змогу зберегти ефективність моделі на попередніх завданнях і водночас розширити її можливості для роботи з новими викликами.

Після завершення поступового навчання модель проходить ретельну оцінку. Тестування проводиться як на попередніх даних, так і на нових наборах, щоб упевнитися, що вона зберегла здатність виконувати попередні завдання та успішно інтегрувала нові знання. Такий підхід дозволяє досягти балансу між стабільністю моделі та її здатністю до адаптації.

Переваги поступового навчання особливо цінні в умовах пандемії COVID-19. Цей підхід значно економить обчислювальні ресурси, оскільки

оновлення моделі виконується лише частково, без повного перенавчання. Це особливо важливо, коли вірус швидко еволюціонує, і необхідно оперативно інтегрувати нові дані. Поступове навчання також дозволяє уникнути явища "катастрофічного забування", коли модель втрачає здатність виконувати раніше освоєні завдання. Завдяки цьому підходу штучний інтелект стає більш гнучким і ефективним у вирішенні складних завдань, пов'язаних із COVID-19.

В заключенні до цього розділу, у висновку можна зазначити, що попередньо навчені моделі є потужним інструментом для вирішення завдань, пов'язаних з COVID-19, завдяки їх здатності адаптуватися до нових умов і даних. Принцип їх роботи базується на використанні великих обсягів даних для попереднього навчання, що дозволяє моделі розпізнавати важливі патерни, навіть коли вони застосовуються до нових випадків або варіантів вірусу. Ключовими аспектами є перенос знань та поступове навчання, що дозволяє додавати нові дані без необхідності повного перенавчання.

Завдяки цьому принципу попередньо навчені моделі можуть оперативно адаптуватися до змін, таких як нові штами вірусу або змінені клінічні протоколи. Вони ефективно використовуються для діагностики, прогнозування та аналізу, знижуючи навантаження на медичні установи і допомагаючи в прийнятті важливих рішень. Оскільки ці моделі постійно оновлюються, вони забезпечують точність навіть у динамічних і непередбачуваних умовах, таких як пандемія COVID-19. Таким чином, попередньо навчені моделі, завдяки своїм принципам роботи та здатності до поступового навчання, є важливим елементом у розвитку інструментів штучного інтелекту, що можуть швидко і ефективно адаптуватися до нових викликів у сфері охорони здоров'я, допомагаючи в боротьбі з пандемією.

## **2.3 VGG-16 для діагностики COVID-19**

У цьому розділі розглядається використання глибоких нейронних

мереж, зокрема архітектури VGG-16, для діагностики COVID-19, однієї з найважливіших та найскладніших медичних проблем сучасності. Від початку пандемії COVID-19, що була викликана новим коронавірусом SARS-CoV-2, медична спільнота зіткнулася з необхідністю розробки ефективних методів діагностики, які б могли забезпечити швидке та точне виявлення захворювання серед пацієнтів. Традиційні методи діагностики, такі як ПЛР-тести, хоч і залишаються основними, однак мають низку обмежень, зокрема через тривалість обробки результатів та потребу в специфічному обладнанні. Враховуючи це, комп'ютерне бачення і методи штучного інтелекту (ШІ), зокрема глибоке навчання, стають дедалі популярнішими для створення альтернативних способів діагностики, зокрема на основі медичних зображень, таких як рентгенограми та комп'ютерні томограми (КТ) легень.

VGG-16 є однією з найпопулярніших і найефективніших архітектур для обробки зображень, яка була представлена у 2014 році дослідниками з Оксфордського університету. Її основною перевагою є простота та потужність для задач комп'ютерного зору, таких як класифікація та розпізнавання об'єктів на зображеннях. Назва "16" відображає загальну кількість шарів у моделі, які містять параметри (згорткові шари, шари активації, та повнозв'язні шари).

VGG-16 відома своїм уніфікованим підходом до дизайну шарів. Усі згорткові шари використовують ядра фіксованого розміру  $3 \times 3$  із кроком 111, що дозволяє моделі поступово "бачити" деталі на різних рівнях. На ранніх етапах мережа виділяє низькорівневі ознаки, такі як контури чи текстури. У середніх шарах вона зосереджується на більш складних структурах, а у глибших шарах розпізнає абстрактні ознаки, такі як форми чи об'єкти. Після кожного кількох згорткових шарів додається шар об'єднання (max pooling), який зменшує просторову розмірність даних, що значно знижує обчислювальні витрати й зберігає суттєві характеристики.

VGG-16 також використовує функцію активації ReLU (Rectified Linear

Unit), яка прискорює тренування моделі за рахунок нелінійності, дозволяючи мережі вивчати складні взаємозв'язки між входами та виходами. У фінальній частині мережі є три повнозв'язні шари, що завершуються функцією softmax для класифікації.

Використання VGG-16 зазвичай включає перенесене навчання (transfer learning). Це означає, що модель спочатку навчається на великому наборі даних, наприклад, ImageNet, а потім адаптується до конкретного завдання. Для цього змінюють вихідні шари, щоб вони відповідали кількості класів у новій задачі. Цей підхід дозволяє скоротити час і ресурси для тренування, особливо у випадках, коли доступ до великих медичних датасетів обмежений.

Наприклад, для задачі діагностики COVID-19 VGG-16 можна застосувати для класифікації рентгенівських знімків легень. Спочатку модель завантажується з попередньо навченими вагами, після чого її адаптують для медичних зображень. Цей процес включає донавчання на специфічному наборі даних, що містить категорії, такі як знімки здорових людей, пацієнтів із пневмонією чи COVID-19. Аугментація даних, наприклад, повороти, масштабування чи віддзеркалення зображень, допомагає розширити обсяг даних і покращити генералізацію моделі. Загалом, VGG-16 – це багаторівнева модель, яка спочатку виділяє прості ознаки, потім аналізує складніші структури і, зрештою, класифікує зображення. Це робить її надзвичайно потужною для задач класифікації. Архітектура VGG-16 складається з чотирьох основних частин: вхідного шару, прихованих шарів, шарів Dropout і вихідного шару.

На початку є вхідний шар, який приймає зображення розміром  $224 \times 224 \times 3$ , де 224 – це висота й ширина зображення, а 3 – кількість кольорових каналів (RGB).




Рисунок 2. 6 – Структура мережі VGG-16

Далі йдуть приховані шари, які є основною частиною моделі. Вони складаються з багатьох згорткових шарів, які витягують ознаки зображення, таких як контури, текстури чи форми. У кожному згортковому шарі використовуються маленькі фільтри розміром  $3 \times 3$ , які поступово покривають усе зображення, аналізуючи його на рівні пікселів. Згорткові шари групуються у блоки, і після кожного блоку додається шар MaxPooling. Цей шар зменшує розмір даних, виділяючи лише найважливіші ознаки. Наприклад, після перших шарів кількість фільтрів становить 64, але поступово збільшується до 512 у глибших шарах.

Щоб уникнути перенавчання, у моделі додаються Dropout-шари, які випадковим чином "вимикають" частину нейронів під час тренування. Це дозволяє моделі навчатися більш стійко, знижуючи ризик адаптації до шуму в даних. Dropout використовується перед повнозв'язними шарами, оскільки вони мають найбільшу кількість параметрів і найбільший ризик перенавчання.

Після згорткових шарів дані передаються до повнозв'язних шарів, які працюють як звичайна штучна нейронна мережа. У VGG-16 їх три: два мають по 4096 нейронів і відповідають за обробку великих обсягів інформації, а останній – вихідний шар, де кількість нейронів дорівнює

кількості класів (наприклад, 1000 для ImageNet). У вихідному шарі використовується функція активації Softmax, яка перетворює результати в ймовірності належності до кожного класу.




Рисунок 2. 7 – Зображення архітектури VGG-16

VGG-16 має кілька ключових переваг, які роблять її популярною для задач класифікації зображень. Головною перевагою є її проста та ефективна архітектура, яка базується на використанні невеликих згорткових фільтрів розміром  $3 \times 3$ , що дозволяє моделі поступово виділяти суттєві ознаки зображення на різних рівнях деталізації. Завдяки цьому вона здатна успішно розпізнавати складні структури, об'єкти та патерни в зображеннях. Іншою важливою перевагою є те, що модель була попередньо навчена на великому датасеті ImageNet, що дає можливість використовувати її у різних задачах за допомогою перенесеного навчання, зменшуючи потребу в зборі великих спеціалізованих наборів даних. VGG-16 добре узагальнює нові дані завдяки своїй глибокій структурі та високій кількості параметрів, що дозволяє їй досягати високої точності. Крім того, уніфікована архітектура робить її зручною для адаптації до інших задач, таких як сегментація або генерація

зображень. Її застосування визнане в багатьох галузях, включаючи медицину, завдяки здатності аналізувати зображення високої складності. Попри те, що модель потребує значних обчислювальних ресурсів, її ефективність та висока точність роблять її важливим інструментом у комп'ютерному зорі.

Використання VGG-16 для класифікації COVID-19 на рентгенівських знімках легень за допомогою фреймворка Keras має кілька значних переваг. По-перше, VGG-16 є перевіреною моделлю з високою точністю класифікації, яка була попередньо навчена на великому наборі даних ImageNet. Це дозволяє використовувати перенесене навчання для адаптації моделі до задач класифікації медичних зображень, включаючи рентгенівські знімки. Цей підхід скорочує час тренування та знижує вимоги до великих спеціалізованих датасетів, що є важливим у медичній сфері, де доступ до якісних даних обмежений.

По-друге, структура VGG-16 дозволяє ефективно виділяти ознаки, навіть у складних медичних зображеннях. Глибокі згорткові шари здатні аналізувати текстури, контури та інші ознаки, характерні для патологій у легенях, таких як COVID-19, і робити це на високому рівні деталізації. Модель може добре розрізняти здорові легені, легені з пневмонією та легені, уражені COVID-19.

Фреймворк Keras надає зручні інструменти для завантаження попередньо навчених вагів VGG-16 і модифікації вихідного шару під конкретну задачу (наприклад, для класифікації на два або три класи: здорові, пневмонія, COVID-19). Завдяки інтуїтивному інтерфейсу Keras, користувачі можуть легко додати шари Dropout для запобігання перенавчанню або налаштувати параметри оптимізатора для покращення результатів.

Ще однією перевагою є можливість використовувати техніки аугментації даних, які доступні в Keras. Це дозволяє збільшити обсяг навчальних даних шляхом створення нових зображень (наприклад, за допомогою поворотів, масштабування чи віддзеркалень), що особливо

корисно для невеликих медичних наборів даних.

Крім того, VGG-16 добре інтегрується з фреймворком TensorFlow, що дозволяє використовувати апаратне прискорення на GPU для прискорення тренування. У підсумку, використання VGG-16 у класифікації рентгенівських знімків COVID-19 із застосуванням Keras забезпечує високу точність, швидкість розробки, доступність потужних інструментів і можливість легкої адаптації моделі до специфічних вимог задачі.




Рисунок 2.8 – Приклад класифікації зображень X-Ray у використанні VGG-16

Основними недоліками VGG-16 є висока обчислювальна складність і значний обсяг параметрів (понад 138 мільйонів), що потребує великої кількості пам'яті та потужного апаратного забезпечення для тренування та застосування моделі. Це робить її менш практичною для використання в реальному часі чи на пристроях із обмеженими ресурсами. Також модель схильна до перенавчання на невеликих наборах даних, якщо не використовувати спеціальні техніки, як-от Dropout або аугментацію даних. Ще одним недоліком є негнучкість щодо адаптації до різномірних даних без значного перенавчання, оскільки її архітектура менш оптимізована для

медичних зображень порівняно з новішими моделями, такими як ResNet або EfficientNet.

GG-16 є однією з найпотужніших і широко використовуваних моделей для класифікації зображень, включаючи медичні задачі, як-от виявлення COVID-19 на рентгенівських знімках. Її головними перевагами є ефективність у виділенні ознак, можливість перенесеного навчання, що значно полегшує адаптацію до медичних даних, і висока точність класифікації навіть у задачах із малими наборами даних. Однак модель має значні недоліки, такі як обчислювальна складність, потреба в потужному апаратному забезпеченні й великий ризик перенавчання без належної обробки даних.

Попри це, завдяки зручній реалізації в фреймворках, таких як Keras, VGG-16 залишається популярним інструментом для дослідників у сфері комп'ютерного зору та медичної діагностики, забезпечуючи важливий баланс між простотою застосування та точністю результатів. Для подальшого покращення продуктивності її часто поєднують із сучасними методами аугментації даних, оптимізації і більш новими моделями нейронних мереж.

## **2.4 Keras: Інструменти та бібліотеки для обробки зображень**

У сучасному технологічному світі зображення стали універсальною формою даних. Від платформ соціальних медіа до діагностики охорони здоров'я зображення знаходяться в центрі інновацій. Однак отримання значущої інформації з візуальних даних є складним завданням, яке потребує надійних і ефективних інструментів. Машинне навчання, особливо глибоке навчання, революціонізувало наш підхід до задач обробки зображень, наприклад, виявлення об'єктів, сегментація зображень, розпізнавання облич і навіть творчі програми, такі як передача стилю або генерація зображень.

Завдяки інтеграції в системи громадського здоров'я, Keras сприяв

моніторингу випадків COVID-19 в реальному часі та підтримував зусилля з відстеження контактів, що є важливим для обмеження поширення вірусу. Платформа також допомогла в розробці систем підтримки клінічних рішень, що допомагають медичним працівникам оцінювати ризики пацієнтів і оптимізувати плани лікування на основі різних факторів здоров'я.

У всіх цих сферах Keras продемонстрував свою універсальність і цінність, допомагаючи медичним працівникам, дослідникам та організаціям охорони здоров'я ефективніше реагувати на пандемію COVID-19. Поточне використання Keras в охороні здоров'я та дослідженнях продовжує пропонувати перспективні рішення для подолання викликів, спричинених вірусом.

Keras — це високорівнева бібліотека для побудови і тренування нейронних мереж, яка працює поверх інших бібліотек глибокого навчання, як TensorFlow, Theano або Microsoft Cognitive Toolkit. Була розроблена для того, щоб полегшити процес створення моделей машинного навчання, роблячи його більш інтуїтивно зрозумілим та доступним навіть для початківців. Keras надає прості API для побудови, навчання та оцінки нейронних мереж, яке дозволяє користувачам легко проводити експерименти з різними архітектурами. Завдяки своїй простоті й зручності використання, Keras стала дуже популярною у світі глибокого навчання. Однак з часом Keras було інтегровано безпосередньо в TensorFlow як частину його API, що зробило її ще більш зручною для користувачів цієї платформи.

Keras варто використовувати через її простоту та зручність для розробки нейронних мереж. Вона має інтуїтивно зрозумілий API для створення, навчання та оцінки нейронних мереж, яке дає змогу користувачам легко проводити експерименти з різними моделями, навіть без глибоких знань в області програмування або машинного навчання. Крім того, Keras дозволяє легко налаштовувати складні моделі, використовуючи вже готові компоненти, такі як шари, оптимізатори та функції активації. Це дає змогу

значно прискорити процес розробки та тестування нових ідей.

Ще одна важлива перевага Keras — це її сумісність з TensorFlow, що дає змогу використовувати потужні інструменти для тренування і масштабування моделей. Від версії TensorFlow 2.0, Keras є частиною цього фреймворка в межах модуля *tf.keras*, що дозволяє розробникам швидко створювати та тренувати моделі нейронних мереж без необхідності занурюватися в складні деталі низькорівневого API TensorFlow. Keras надає доступ до широкого спектра функцій, таких як підтримка різних типів нейронних мереж, таких як, згорткових і рекурентних, а також можливість використання попередньо натренованих моделей. Завдяки цьому, вона стає ідеальним вибором для тих, хто хоче швидко і ефективно створювати моделі глибокого навчання без необхідності занурюватися в деталі низькорівневих операцій.

TensorFlow — це потужний фреймворк для машинного навчання, розроблений Google. TensorFlow спочатку був розроблений дослідниками та інженерами, які працюють у команді Machine Intelligence у Google Brain для проведення досліджень машинного навчання та нейронних мереж. Однак фреймворк досить універсальний, щоб використовувати його також і в інших сферах.[16] Він дозволяє створювати, тренувати і застосовувати моделі для різноманітних завдань машинного навчання, таких як класифікація, регресія, прогнозування, обробка природної мови (NLP) та розпізнавання зображень. TensorFlow підтримує різні типи моделей, включаючи нейронні мережі, й забезпечує гнучкість у налаштуванні та оптимізації цих моделей.

TensorFlow використовує концепцію графів обчислень, де кожен вузол графа представляє математичну операцію (наприклад, множення або додавання), а ребра між вузлами представляють багатовимірні масиви даних, відомі як тензори. Це дозволяє ефективно виконувати обчислення на великих обсягах даних, що є критичним для задач глибокого навчання.

Основні особливості TensorFlow:

1. Гнучкість і масштабованість: TensorFlow підтримує розподілене

навчання, що дає можливість використовувати кілька графічних процесорів (GPU) або тензорних процесорів (TPU) для прискорення обчислень.

2. Модульність: TensorFlow пропонує як низькорівневі, так і високорівневі API, що дає змогу застосовувати його як для складних, так і для простих моделей.
3. TensorFlow Hub та TensorFlow Lite: Інструменти для роботи з попередньо навченими моделями та оптимізації моделей для мобільних пристроїв і вбудованих систем.
4. TensorFlow.js та TensorFlow Extended (TFX): Рішення для запуску моделей у браузері або для створення повних пайплайнів машинного навчання.

Ще однією цікавою технічною особливістю є використання callbacks. Це спеціальні функції, які виконуються під час тренування моделі, наприклад, для збереження моделі після кожної епохи або для ранньої зупинки, щоб уникнути перенавчання. Найбільш поширеним є ModelCheckpoint, який дозволяє зберігати найкращу модель, або EarlyStopping, що зупиняє тренування, коли модель не покращує результат протягом декількох епох.

Keras також підтримує розподілене тренування за допомогою MultiWorkerMirroredStrategy для тренування моделей на кількох GPU або навіть на кількох машинах, що дозволяє працювати з великими наборами даних. Це важливо при роботі з великими моделями або великими обсягами даних, де один GPU може бути недостатньо ефективним.

Ще одна технічна особливість Keras — це здатність використовувати TensorFlow Hub для інтеграції попередньо натренованих моделей. Це дозволяє економити час на тренування та досягати високих результатів при обробці нових даних, використовуючи вже натреновані моделі на величезних наборах даних. Крім того, Keras дозволяє використовувати інші ресурси для оптимізації, такі як XLA (Accelerated Linear Algebra), що

допомагає прискорити виконання операцій в TensorFlow, роблячи тренування більш ефективним.

Завдяки своїй інтеграції з TensorFlow, Keras підтримує роботу з TensorFlow Lite для розгортання моделей на мобільних пристроях або вбудованих системах, а також TensorFlow.js для використання моделей у браузері, що дає можливість запускати моделі машинного навчання прямо на клієнтських пристроях без необхідності в серверній інфраструктурі.

Моделі створюються за допомогою різних API, Keras, що дозволяє будувати як прості, так і складні нейронні мережі, такі як згорткові (CNN), рекурентні (RNN) та трансформери. Для навчання моделей у Keras часто використовують оптимізатор Adam (Adaptive Moment Estimation). Adam є адаптивним методом оптимізації, який комбінує переваги двох інших популярних методів: AdaGrad та RMSprop. Він автоматично налаштовує швидкість навчання для кожного параметра моделі, що дозволяє швидше та ефективніше досягати мінімуму функції втрат. Оптимізатор відповідає за оновлення ваг моделі на основі обчисленої функції втрат, щоб мінімізувати її значення.

У Keras можна використовувати Adam просто, вказавши його в якості оптимізатора при компіляції моделі:

```
from tensorflow.keras.optimizers import Adam

model.compile(optimizer=Adam(), loss='categorical_crossentropy', metrics=['accuracy'])
```

Рисунок 2.9 – Використання Adam

Використаємо оптимізатор Адама, щоб досягти глобальних мінімумів під час навчання моделі. Якщо ми застрягли в локальних мінімумах під час навчання, тоді оптимізатор Адама допоможе нам вийти з локальних мінімумів і досягти глобальних мінімумів. Ми також вкажемо швидкість

навчання оптимізатора, тут у цьому випадку вона встановлена на 0,001. Якщо наше навчання сильно змінюється в епохах, тоді нам потрібно зменшити швидкість навчання, щоб ми могли досягти глобальних мінімумів.[17]

Коли модель готова і визначені функція втрат та оптимізатор, можна приступати до тренування. Тренування відбувається за допомогою методу *fit()*, який здійснює багаторазові проходи через навчальний набір даних. Під час кожного етапу модель обчислює передбачення, порівнює їх з істинними значеннями за допомогою функції втрат, і оновлює свої параметри, щоб мінімізувати помилку. У цьому прикладі модель тренується протягом 5 епох з використанням навчальних і валідаційних даних для оцінки її продуктивності на кожному етапі.

```
model.fit(x_train, y_train, epochs=10, batch_size=32, validation_data=(x_val, y_val))
```

Рисунок 2.10 – Базовий приклад використання методу *fit()*

Для оцінки продуктивності моделі на тестовому наборі даних після тренування в Keras використовується метод *evaluate()*. Цей метод обчислює значення функції втрат та метрик, таких як точність, на тестовому наборі, який не використовувався під час навчання.

```
test_loss, test_accuracy = model.evaluate(x_test, y_test)
```

Рисунок 2.11 - приклад використання методу *evaluate()*

Після оцінки продуктивності моделі можна приступити до її удосконалення. Це може включати в себе налаштування гіперпараметрів,

таких як кількість шарів, кількість нейронів у шарах, швидкість навчання, а також використання різних технік регуляризації, щоб уникнути перенавчання. Можна також використовувати методи, такі як перенавчання (transfer learning), де модель попередньо тренується на великих наборах даних і потім донавчається для конкретної задачі.

Після того як модель продемонструє хороші результати на тестових даних, її можна зберегти для подальшого використання або розгортання на продуктивних системах.

Навчання моделей у Keras є важливим етапом у створенні ефективних систем машинного навчання. Завдяки гнучкості та потужності цього фреймворка, розробники можуть швидко прототипувати різні моделі, налаштовувати їх для досягнення найкращих результатів та масштабувати їх для обробки великих обсягів даних.

У результаті використання Keras в боротьбі з пандемією COVID-19 можна зробити висновок, що технології машинне навчання відіграє важливу роль у забезпеченні швидкої та ефективної відповіді на виклики, пов'язані з цією хворобою. Завдяки можливостям Keras, медичні працівники отримали інструменти для швидкого та точного аналізу медичних зображень, таких як рентгенівські знімки та МРТ-скани, що сприяє ранній діагностиці та оцінці стану пацієнтів. Прогностичні моделі допомогли прогнозувати поширення вірусу, що дозволило органам охорони здоров'я вчасно вжити заходів для зниження впливу пандемії. Окрім цього, застосування в дослідженнях нових ліків і вакцин значно прискорило процес пошуку ефективних методів лікування та запобігання поширенню хвороби. Використання Keras в роботизованих системах та у громадському здоров'ї допомогло знизити ризик поширення вірусу через автоматизацію деяких процесів. Таким чином, Keras не лише демонструє потужність машинного навчання у медичних дослідженнях, а й виступає незамінним інструментом у боротьбі з глобальними викликами, що з'явилися через пандемію COVID-19.

## РОЗДІЛ 3. РЕАЛІЗАЦІЯ КЛАСИФІКАЦІЇ МЕДИЧНИХ ЗОБРАЖЕНЬ ДЛЯ ВИЯВЛЕННЯ COVID-19

### 3.1 Підготовка набору медичних зображень для класифікації

Підготовка даних є одним із найважливіших етапів у побудові систем машинного навчання, оскільки якість і репрезентативність вибірки безпосередньо впливають на точність моделі. Для задачі класифікації медичних зображень, особливо у випадку виявлення COVID-19 на рентгенівських знімках легень, правильна організація даних має вирішальне значення.

Визначальною рисою даних для медичної діагностики є їх обмежений доступ та залежність результатів від якості знімків і правильної розмітки. Тому важливо зосередитися на отриманні даних з авторитетних джерел, таких як медичні бази даних, та на їхній ретельній підготовці перед використанням у навчанні моделі. Крім того, необхідно забезпечити баланс між класами, адже в медичних вибірках зазвичай зустрічається дисбаланс, коли кількість знімків хворих пацієнтів значно менша, ніж здорових.

Для підвищення ефективності класифікації, крім збору та аналізу вихідних даних, також здійснюється їх попередня обробка: масштабування, нормалізація, а також застосування технік аугментації для збільшення обсягу даних. Це дозволяє створити більш універсальну модель, здатну адаптуватися до різноманітних варіантів зображень у реальних умовах.

При роботі з рентгенівськими знімками для класифікації модуль Keras Applications пропонує, вже навченої на ImageNet, підготовка набору медичних зображень має специфічні особливості. Рентгенівські знімки — це тип медичних зображень, які часто використовуються для діагностики різних захворювань, таких як пневмонія, переломи, рак та інші патології. Вони мають низьку контрастність і специфічні деталі, що потребує особливої уваги при підготовці даних для моделі.

Вибір Keras і Python для розробки моделей машинного навчання та глибокого навчання має кілька важливих переваг, що робить ці інструменти дуже популярними серед дослідників, інженерів та розробників. Ось основні причини, чому саме Keras і Python є такими популярними для таких задач. Python є однією з найпростіших і зрозумілих мов програмування, з мінімалістичним і інтуїтивно зрозумілим синтаксисом, що дозволяє швидко писати, читати та підтримувати код. Це особливо важливо для дослідників і розробників, які хочуть швидко експериментувати з ідеями та розробляти нові моделі. Крім того, Python має велику кількість бібліотек для наукових обчислень і машинного навчання, таких як NumPy, Pandas, Matplotlib, SciPy, Scikit-learn, TensorFlow, Keras і PyTorch, що дає можливість ефективно працювати з даними та реалізовувати складні моделі.

Python також підтримує активну спільноту і має багатий набір ресурсів для навчання, що дає змогу швидко знаходити рішення для різних завдань.

Важливою перевагою є відкритий код Python, що дає можливість вільно використовувати його як для особистих, так і для комерційних цілей. Завдяки гнучкості Python можна інтегрувати з іншими мовами програмування та платформами, що дозволяє створювати більш комплексні рішення.

Keras, у свою чергу, є потужним інструментом для побудови нейронних мереж завдяки своїй високій абстракції, що значно спрощує процес створення моделей. Більшість задач можна вирішити лише кількома рядками коду, що робить його ідеальним для швидкого прототипування. Keras інтегровано з TensorFlow, що дає доступ до всіх потужних можливостей цієї платформи, зокрема для тренування і оптимізації моделей. Більше того, Keras підтримує багато популярних архітектур, таких як CNN для обробки зображень, RNN для послідовностей, а також спеціалізовані моделі, такі як LSTM та GRU.

Ще однією важливою перевагою Keras є його модульність і розширюваність. Користувачі можуть створювати власні шари,

оптимізатори, метрики, що дозволяє адаптувати бібліотеку під специфічні потреби проекту. Крім того, Keras надає вбудовані попередньо натреновані моделі, які значно скорочують час на навчання і дають можливість швидко адаптувати моделі до нових даних. Завдяки цьому можна ефективно використовувати вже натреновані моделі для специфічних завдань, таких як класифікація зображень чи тексту.

Вибір Python і Keras для розробки моделей глибокого навчання є логічним через їх простоту, гнучкість і велику кількість інструментів і бібліотек, які значно спрощують процес розробки, тестування і впровадження моделей машинного навчання. Ці інструменти ідеально підходять як для новачків, так і для досвідчених розробників, що працюють над складними проектами в сфері штучного інтелекту.

Першим етапом є збір рентгенівських знімків з медичних установ або публічних баз даних, таких як NIH Chest X-ray Dataset або Kaggle. Рентгенівські зображення можуть бути у форматах, таких як DICOM або JPEG, і потребують попередньої обробки, щоб привести їх до стандартів, з якими працює модель ImageNet. Це передбачає зміни розміру зображень (наприклад, до 224x224 пікселів) і нормалізацію пікселів для узгодження з тими значеннями, які використовуються в стандартній моделі ImageNet.

Додатково важливо врахувати, що рентгенівські знімки можуть мати шум, варіації освітлення або артефакти, що виникають під час процесу знімання. Для цього застосовуються методи попередньої обробки, такі як фільтрація шуму або корекція контрасту, щоб підготувати зображення до навчання. Аугментація зображень, наприклад, шляхом випадкових обертів, зміщень або змін яскравості, також допомагає моделі краще справлятися з різними варіаціями в даних.

Після попередньої обробки, рентгенівські зображення можна використовувати для донавчання вже існуючої моделі, навченого на ImageNet. Для цього можна використовувати техніку донавчання з замороженими шарами для більш загальних ознак, що відповідають за

детекцію контурів та інших базових характеристик, і розкриття нових шарів для спеціалізації на рентгенівських зображеннях, наприклад, для виявлення специфічних захворювань або аномалій.

Оскільки рентгенівські зображення часто мають специфічні особливості, такі як необхідність точного визначення меж органів або локалізації патологічних змін, спеціалізовані техніки, як контурна детекція, можуть бути додані до обробки зображень перед передачею їх у модель. Це дозволить моделі фокусуватися на більш важливих частинах зображення, зокрема на тих ділянках, де можуть бути присутні патології.

На платформі Kaggle є кілька відкритих наборів даних, пов'язаних із рентгенівськими знімками грудної клітки для діагностики COVID-19. Ось кілька популярних наборів даних, які можуть бути корисними:

1. COVID-19 Radiography Database. Це один із найбільш популярних наборів даних, який містить рентгенівські знімки хворих на COVID-19, а також знімки для інших респіраторних захворювань та здорових пацієнтів.
2. COVID-19 Chest X-Ray Dataset. Цей набір містить знімки хворих на COVID-19, пневмонію та здорових людей. Він підходить для навчання моделей класифікації.
3. RSNA Pneumonia Detection Challenge Dataset. Хоча цей набір даних першопочатково створювався для визначення пневмонії, його можна адаптувати для роботи з COVID-19, якщо комбінувати з іншими джерелами.
4. COVIDx Dataset. Цей набір даних зібраний із декількох відкритих джерел і містить великий обсяг зображень для аналізу COVID-19.

Набір даних COVID-19 Chest X-Ray Dataset є колекцією рентгенівських знімків грудної клітки, створеною для досліджень у галузі медичної інформатики та машинного навчання. Цей набір даних використовується для розробки автоматизованих методів діагностики

COVID-19 та інших респіраторних захворювань. Він включає понад 5000 зображень грудної клітки, які належать до кількох категорій: COVID-19, пневмонія (вірусна або бактеріальна) та здоровий стан.




Рисунок 3.1 – Набір даних з 3 категоріями

Зображення поділені на навчальний і тестовий набори, що забезпечує зручність для навчання та оцінювання моделей.

Додатково, разом із зображеннями, надаються метадані у вигляді таблиці, де вказані вік, стать пацієнта, вид діагнозу та інші клінічні дані. Цей набір ідеально підходить для побудови класифікаційних моделей, виявлення патернів у знімках і подальшого використання в медичній практиці.




Рисунок 3.2 – Набір тестовий та навчальний

### 3.2 Класифікація зображень на попередньо навчених моделях

Для того, щоб провести класифікацію, потрібно або навчити або використати вже навчену модель штучного інтелекту, для виявлення Covid-19. Для процесу класифікації з використанням Keras ImageNet передбачає застосування попередньо тренованих моделей, які були навчання на великому наборі даних ImageNet для задачі класифікації зображень. будемо використовувати трансферне навчання і будувати згорткову нейронну мережу на основі вже навчених та тренованих моделей, оскільки вони пройшли вже всі помилки, аналізи та містяться у модулі Keras Application. Це дозволяє використовувати потужні моделі з уже навченою здатністю до розпізнавання різних об'єктів на зображеннях, адаптуючи їх під конкретне завдання за допомогою перенесеного навчання. Перш за все, необхідно імпортувати відповідні модулі з Keras для побудови пакети, завантаження попередньо тренованих мереж та обробки зображень.

Існує багато попередньо тренованих мереж в цьому модулі, але не дивлячись на отримані результати цих мереж, вони можуть видозмінюватися в залежності від їх використання. Попередньо треновані моделі значно прискорюють розробку нейромережових рішень і забезпечують високу якість навіть при обмежених обсягах даних. Нам представлений вибір моделі, який ще можна поділити на три види. Перший для швидкості MobileNet або EfficientNetB0. Наступне для високої точності: ResNet, DenseNet, або InceptionV3. І для збалансованої продуктивності: VGG16, EfficientNetB3.

## Available models

| Model             | Size   | Top-1 Accuracy | Top-5 Accuracy | Parameters  | Depth |
|-------------------|--------|----------------|----------------|-------------|-------|
| Xception          | 88 MB  | 0.790          | 0.945          | 22,910,480  | 120   |
| VGG16             | 528 MB | 0.713          | 0.901          | 138,357,344 | 23    |
| VGG19             | 549 MB | 0.713          | 0.900          | 143,667,240 | 26    |
| ResNet50          | 98 MB  | 0.749          | 0.921          | 25,636,712  | -     |
| ResNet101         | 171 MB | 0.764          | 0.928          | 44,707,176  | -     |
| ResNet152         | 232 MB | 0.766          | 0.931          | 60,419,944  | -     |
| ResNet50V2        | 98 MB  | 0.760          | 0.930          | 23,613,800  | -     |
| ResNet101V2       | 171 MB | 0.772          | 0.938          | 44,675,560  | -     |
| ResNet152V2       | 232 MB | 0.780          | 0.942          | 60,380,640  | -     |
| InceptionV3       | 92 MB  | 0.779          | 0.937          | 21,851,784  | 154   |
| InceptionResNetV2 | 215 MB | 0.803          | 0.953          | 55,873,736  | 272   |
| MobileNet         | 10 MB  | 0.704          | 0.895          | 4,253,804   | 88    |
| MobileNetV2       | 14 MB  | 0.711          | 0.901          | 1,478,464   | 80    |
| DenseNet121       | 13 MB  | 0.750          | 0.923          | 6,082,504   | 121   |
| DenseNet169       | 57 MB  | 0.762          | 0.932          | 14,107,100  | 169   |
| DenseNet201       | 80 MB  | 0.773          | 0.936          | 20,242,984  | 201   |
| NASNetMobile      | 25 MB  | 0.744          | 0.919          | 5,326,716   | -     |
| NASNetLarge       | 343 MB | 0.825          | 0.960          | 88,949,818  | -     |
| EfficientNetB0    | 29 MB  | -              | -              | 5,330,571   | -     |
| EfficientNetB1    | 31 MB  | -              | -              | 7,856,230   | -     |
| EfficientNetB2    | 36 MB  | -              | -              | 9,177,560   | -     |
| EfficientNetB3    | 48 MB  | -              | -              | 12,320,535  | -     |
| EfficientNetB4    | 75 MB  | -              | -              | 19,486,823  | -     |
| EfficientNetB5    | 118 MB | -              | -              | 30,562,527  | -     |
| EfficientNetB6    | 166 MB | -              | -              | 43,265,143  | -     |
| EfficientNetB7    | 256 MB | -              | -              | 66,658,687  | -     |

Рисунок 3.3 – Попередньо навчені моделі у модулі Keras Application

Для визначення найбільш ефективніших моделі, було відібрано наступні мережі: VGG16, ResNet152V2, DenseNet201 та InceptionResNetV2. Але оптимізатор було вибрано Adam, адже він найбільш показує точність мережі. Провівши тести і визначивши, яка модель все ж таки займає перевагу в цьому списку для нашої роботи, було вибрано попередньо навчену модель VGG16.

| Назва моделі      | Точність (%) | Помилка (%) |
|-------------------|--------------|-------------|
| VGG16             | 97.5         | 2.5         |
| ResNet152V2       | 94.2         | 5.8         |
| DenseNet201       | 92.7         | 7.3         |
| InceptionResNetV2 | 95.0         | 5.0         |

Таблиця 3.1 - Використання попередньо навчених моделей і їх тестування на точність та помилковість

Завантажемо попередньо натреновану модель VGG16 з вагами ImageNet, де `weights='imagenet'`: використовує попередньо натреновані ваги на ImageNet;

- `include_top=False`: не включає останній шар для класифікації, щоб ми могли додати власні шари для задачі;
- `input_shape=(224, 224, 3)`: вказує розмір вхідного зображення (224x224 пікселів, 3 канали кольору).

```
base_model = VGG16(weights='imagenet', include_top=False, input_shape=(224, 224, 3))
```

Рисунок 3.4 – Завантаження попередньо навченої моделі

Один цикл повного проходу через увесь тренувальний набір даних – епоха. Під час кожної епохи модель оновлює свої параметри (ваги) на основі помилок, яких вона припускається під час прогнозування на тренувальних даних. Більша кількість епох може покращити якість моделі, але при цьому може призвести до перенавчання (overfitting), коли модель занадто точно вивчає тренувальні дані і погано працює на нових, невідомих даних.

Зазвичай для визначення оптимальної кількості епох проводиться тестування на різних значеннях епох і вибирається те, що дає найкращі результати на валідаційних даних. Після тестування різних значень епох для нашої моделі, було виявлено, що оптимальна кількість епох для досягнення найкращих результатів даних знаходиться між 30 та 50 епохами. Під час цих епох модель показала хорошу точність на тренувальних та валідаційних даних без ознак перенавчання.

На графіку точності найкращі результати видно після 30-ї епохи, коли точність на валідаційній вибірці стабільно висока і залишається близькою до тренувальної.

Втрати на валідаційній вибірці мінімальні після ~30-40 епохи і стабілізуються до кінця. Важливо, що вони не збільшуються, що свідчить про відсутність перенавчання.




Рис. 3.5 – Динаміка точності тренування та валідації




Рис. 3.6 – Динаміка втрати тренування та валідації

Підвівши всі підсумки та тренування, кінцевий вигляд архітектури, що основана на Keras та побудована за допомогою штучних нейронних зв'язків, має такий вигляд:

| Layer (type)                     | Output Shape          | Param # |
|----------------------------------|-----------------------|---------|
| input_1 (InputLayer)             | (None, 224, 224, 3)   | 0       |
| block1_conv1 (Conv2D)            | (None, 224, 224, 64)  | 1792    |
| block1_conv2 (Conv2D)            | (None, 224, 224, 64)  | 36928   |
| block1_pool (MaxPooling2D)       | (None, 112, 112, 64)  | 0       |
| block2_conv1 (Conv2D)            | (None, 112, 112, 128) | 73856   |
| block2_conv2 (Conv2D)            | (None, 112, 112, 128) | 147584  |
| block2_pool (MaxPooling2D)       | (None, 56, 56, 128)   | 0       |
| block3_conv1 (Conv2D)            | (None, 56, 56, 256)   | 295168  |
| block3_conv2 (Conv2D)            | (None, 56, 56, 256)   | 590080  |
| block3_conv3 (Conv2D)            | (None, 56, 56, 256)   | 590080  |
| block3_pool (MaxPooling2D)       | (None, 28, 28, 256)   | 0       |
| block4_conv1 (Conv2D)            | (None, 28, 28, 512)   | 1180160 |
| block4_conv2 (Conv2D)            | (None, 28, 28, 512)   | 2359808 |
| block4_conv3 (Conv2D)            | (None, 28, 28, 512)   | 2359808 |
| block4_pool (MaxPooling2D)       | (None, 14, 14, 512)   | 0       |
| block5_conv1 (Conv2D)            | (None, 14, 14, 512)   | 2359808 |
| block5_conv2 (Conv2D)            | (None, 14, 14, 512)   | 2359808 |
| block5_conv3 (Conv2D)            | (None, 14, 14, 512)   | 2359808 |
| block5_pool (MaxPooling2D)       | (None, 7, 7, 512)     | 0       |
| flatten_1 (Flatten)              | (None, 25088)         | 0       |
| dense_1 (Dense)                  | (None, 128)           | 3211392 |
| dense_2 (Dense)                  | (None, 1)             | 129     |
| Total params: 17,926,209         |                       |         |
| Trainable params: 3,211,521      |                       |         |
| Non-trainable params: 14,714,688 |                       |         |

Рисунок 3.7 – Вигляд архітектури

Модель VGG-16 має велику кількість параметрів через свою глибину та складність, що робить її дуже потужною для багатьох завдань комп'ютерного зору. Завдяки використанню попередньо навчених ваг (наприклад, на ImageNet) для специфічних задач (таких як діагностика захворювань), можна використовувати менше параметрів, заморожуючи частину шарів, щоб зменшити кількість навчених параметрів. У моделі є

величезна кількість параметрів завдяки попередньо навченій моделі VGG16, що дає змогу мережі навчатися ефективно навіть на невеликих наборах даних. Попередньо навчена модель VGG16 має 17, 926, 209 параметрів.

### 3.3 Обговорення та аналіз отриманих результатів

Для розробки моделі ми обрали мову програмування Python через її зручність, потужні бібліотеки для глибокого навчання та широку підтримку в галузі машинного навчання. Python є однією з найбільш популярних мов для вирішення задач комп'ютерного зору завдяки своїм зручним інтерфейсам та великій кількості бібліотек, таких як Keras, TensorFlow і PyTorch, які значно спрощують процес розробки та навчання нейронних мереж. Keras, зокрема, дозволяє швидко експериментувати з різними архітектурами моделей і має хорошу інтеграцію з іншими інструментами для роботи з глибоким навчанням.

Модель була навчена за допомогою Python та бібліотеки Keras на основі попередньо навчених ваг VGG-16. Модель має велику кількість параметрів — близько 138 мільйонів, з усіма параметрами навченими, що робить її високопродуктивною, але і досить вимогливою до обчислювальних ресурсів. Всі шари моделі були налаштовані для оптимальної роботи, при цьому ми проводили тестування на кількості епох, що дозволило визначити оптимальну кількість для досягнення найкращих результатів.

Навчання моделі з використанням 30-40 епох продемонструвало найкращі результати для вирішення задачі класифікації COVID-19 на рентгенівських знімках грудної клітки. Це показало, що модель добре узагальнюється на нових даних і здатна ефективно вирізняти зображення з ознаками хвороби від здорових знімків. Час навчання моделі залежав від обсягу даних і конфігурації обладнання, але в середньому процес навчання на 30-40 епохах займав близько 2-3 годин на стандартному GPU. Це дозволило досягти оптимальних результатів без значних затримок.

Після завершення навчання модель показала високу точність

класифікації зображень. Для тестових знімків точність класифікації склала близько 95%. Це означає, що модель ефективно розрізняє рентгенівські знімки з ознаками COVID-19 від здорових зображень, що є важливим для автоматизованої діагностики і підтримки медичних працівників в процесі обстеження пацієнтів.

Отримані класифікації зображень COVID-19 з використанням штучного інтелекту. Виділено зони із ураженням COVID-19, та рентгенівські знімки здорової людини.




Рисунок 3.8 – Результат класифікації зображень( COVID-19/NORMAL)

Для оцінки ефективності застосування штучного інтелекту (ШІ) та традиційних методів діагностики COVID-19 були проведені порівняння за кількома важливими критеріями, такими як точність, швидкість аналізу, здатність обробляти великі обсяги зображень і ефективність при масовому скринінгу.

- Точність діагностики: ІІІ, зокрема методи глибокого навчання, значно

перевершують традиційні методи в точності виявлення COVID-19. За результатами досліджень, автоматизовані системи на основі ІІІ досягають точності понад 90%. Це вкрай важливо в умовах епідемії, де необхідно швидко і точно визначити наявність захворювання, щоб максимально ефективно планувати лікування та профілактичні заходи. Традиційні методи, з іншого боку, можуть мати похибки, що особливо проявляються в умовах стресу або перевантаження лікарів. Так, точність людського огляду на рентгенівських зображеннях часто коливається в межах 80-85%, що є менш ефективним у порівнянні з технологіями ІІІ, які забезпечують більшу консистентність у своїх результатах. [18]

- Швидкість аналізу: ІІІ має суттєву перевагу в швидкості обробки зображень. Аналіз одного рентгенівського знімка займає лише 1-2 секунди, що дозволяє швидко отримувати результати і починати відповідне лікування. У випадку з традиційним методом, коли кожне зображення має бути перевірене лікарем, на це може піти від 10 до 20 хвилин на один знімок, що суттєво збільшує час очікування для пацієнтів та може призвести до затримок в діагностиці, особливо при великих потоках хворих. Швидкість ІІІ дозволяє також значно збільшити ефективність у разі масових перевірок і тестувань, що є важливим аспектом у періоди сплесків захворювання

- Обробка великих обсягів зображень: Важливою перевагою ІІІ є його

здатність обробляти великі обсяги зображень без зниження якості та швидкості аналізу. У разі пандемії чи іншої великої епідемії, коли потрібно швидко обробити тисячі зображень за короткий час, ІІІ є незамінним інструментом. Це дозволяє лікарям зосередитися на більш складних випадках і зменшити навантаження на систему охорони здоров'я. У той час як традиційні методи обмежені людським ресурсом, що може призводити до затримок і перевантаження медичних установ, ІІІ здатен автоматизувати

весь процес, забезпечуючи оперативність і точність.

| Метод                      | Кількість зображень, що аналізуються | Час аналізу (на зображення ) | Точність (правильні відповіді)           |
|----------------------------|--------------------------------------|------------------------------|------------------------------------------|
| Виявлення за допомогою ШІ  | 1 000 зображень                      | 1-2 секунди                  | 92% (понад 90% у багатьох дослідженнях ) |
| Традиційний людський огляд | 1 000 зображень                      | 10-20 хвилин                 | 80-85%                                   |

Таблиця 3.2 - Порівняння методів аналізу рентгенівського зображення для виявлення COVID-19

Проведений аналіз ефективності методів виявлення COVID-19, зокрема порівняння технологій штучного інтелекту (ШІ) та традиційних методів на основі рентгенівських зображень, виявив значні переваги останніх у ряді важливих аспектів, таких як точність діагностики, швидкість обробки зображень та здатність ефективно працювати з великими обсягами даних.

Незважаючи на численні переваги технологій штучного інтелекту, традиційні методи продовжують відігравати важливу роль. Вони залишаються незамінними у випадках, коли необхідна додаткова клінічна інформація або висококваліфікована інтерпретація знімків. Однак штучний інтелект є потужним інструментом, що значно підвищує ефективність і швидкість діагностики COVID-19, доповнюючи традиційні підходи та допомагаючи системам охорони здоров'я справлятися з великими навантаженнями під час глобальних епідемій.

Отже, інтеграція ШІ у медичні процеси є важливим кроком для

покращення діагностики, оптимізації роботи систем охорони здоров'я та забезпечення кращих результатів для пацієнтів. Цей підхід не тільки підвищує точність діагностики, але й сприяє пришвидшенню прийняття рішень, що, в свою чергу, знижує смертність і полегшує перебіг пандемії.

## ВИСНОВОК

У межах дипломної роботи було розроблено систему аналізу медичних зображень для виявлення COVID-19 із використанням методів штучного інтелекту. Головна мета дослідження полягала в створенні ефективного інструменту для автоматичного аналізу рентгенівських знімків легень, що дозволяє ідентифікувати наявність захворювання COVID-19. Для досягнення цієї мети було проведено всебічний аналіз теоретичних основ штучного інтелекту, його застосування у медичній діагностиці, а також сучасних методів глибокого навчання, що є найбільш ефективними для класифікації зображень.

Штучний інтелект є технологією, яка забезпечує здатність комп'ютерних систем виконувати складні завдання, що вимагають імітації людського мислення. До основних переваг ШІ належать висока швидкість обробки даних, точність прогнозів, можливість роботи з великими обсягами інформації та автоматизація процесів. У медичній сфері ШІ набуває дедалі більшого значення, адже він здатний значно покращити якість діагностики, зменшити навантаження на лікарів та забезпечити точність аналізу, яка недоступна людині через обмеження часу чи ресурсів.

COVID-19 — це вірусне захворювання, яке спричинило пандемію з глобальними наслідками для охорони здоров'я, економіки та соціального життя. Важливою складовою боротьби з COVID-19 є своєчасна та точна діагностика. Одним із ефективних способів виявлення захворювання є аналіз рентгенівських знімків грудної клітки, оскільки ураження легень є однією з основних ознак захворювання.

У ході роботи було реалізовано систему класифікації рентгенівських зображень із використанням методів глибокого навчання. Для цього застосовано одну з найпоширеніших моделей нейронних мереж — VGG-16, яка зарекомендувала себе як надійний інструмент для задач комп'ютерного зору. Ця модель була налаштована й адаптована для роботи із задачами класифікації медичних зображень. У процесі розробки використано мову програмування Python, фреймворк Keras для створення та навчання моделі, а також платформу Kaggle, яка надала доступ до відкритих наборів даних рентгенівських знімків.

Значну увагу було приділено підготовці даних, яка включала попередню обробку зображень, нормалізацію даних і їх розділення на тренувальні, валідаційні та тестові вибірки. Це дозволило забезпечити якісне навчання моделі та уникнути проблеми перенавчання. Розроблена система продемонструвала високу ефективність у класифікації рентгенівських знімків, чітко розрізняючи зображення із наявністю COVID-19 та знімки здорових легень. За результатами тестування модель досягла високих показників точності, що свідчить про її надійність та придатність до використання в реальних умовах.

Таким чином, створена система може бути використана як допоміжний інструмент для лікарів у процесі діагностики COVID-19. Вона не лише сприяє підвищенню точності діагностики, але й зменшує час, необхідний для обробки великої кількості знімків, що є особливо важливим у періоди високого навантаження на медичну систему. Робота також відкриває перспективи для подальшого вдосконалення та адаптації подібних систем для діагностики інших захворювань, що базуються на аналізі медичних зображень.

## ПЕРЕЛІК ВИКОРИСТАНИХ ДЛЖЕРЕЛ

1. Rohan Khera. AI in Medicine—JAMA’s Focus on Clinical Outcomes, Patient-Centered Care, Quality, and Equity [Електронний ресурс] / Rohan Khera // Editorial AI in Medicine. – 2023. – URL: <https://jamanetwork.com/journals/jama/fullarticle/2808471>
2. Giovanni Briganti. Frontiers | Artificial Intelligence in Medicine: Today and Tomorrow. Frontiers. URL: <https://www.frontiersin.org/journals/medicine/articles/10.3389/fmed.2020.00027/full>.
3. Esteva, A., Kuprel, B., Mani, S. et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. Nature, 542(7639), 115-118.)
4. Kourou, K., Exarchos, T. P., Karakitsou, K., & Papanikolaou, P. (2015). Machine learning applications in cancer prognosis and prediction. Computational and Structural Biotechnology Journal, 13, 8-17.
5. Yang, G. Z., et al. (2017). The case for artificial intelligence in robotic surgery. The Lancet, 390(10106), 29-30.)
6. ШІ в медицині: переваги та вплив на медичну галузь | Wezom. ІТ-компанія повного циклу розробки програмних продуктів WEZOM - Київ, Україна. URL: <https://wezom.com.ua/ua/blog/shi-v-meditsini-zastosuvannya-perevagi-ta-novi-mozhlivosti>.
7. Humerick, M. Taking AI Personally: How the E.U. Must Learn to Balance the Interests of Personal Data Privacy & Artificial Intelligence. Santa Clara High Tech Law Journal, 2018, pp. 393-396.
8. Alvin Rajkomar. Scalable and accurate deep learning with electronic health records - PubMed. PubMed. URL: <https://pubmed.ncbi.nlm.nih.gov/31304302/>.
9. Adewole S. Adamson, Avery Smith. Machine Learning and Health Care Disparities in Dermatology - PubMed. PubMed. URL: <https://pubmed.ncbi.nlm.nih.gov/30073260/>
10. COVID-19 CT Image Classification and Pneumonia Lesions Segmentation Using Deep Learning // IEEE Xplore. URL: <https://ieeexplore.ieee.org/document/9712109>
11. Yao, Q. та ін. "Label-Free Segmentation of COVID-19 Lesions in Lung CT". IEEE Transactions on Medical Imaging, 2021. URL: <https://ieeexplore.ieee.org/document/9385788>
12. Densely Connected Convolutional Networks (DenseNet) for Diagnosing Coronavirus Disease (COVID-19) from Chest X-ray Imaging, 2021. URL: <https://ieeexplore.ieee.org/document/9478715>.
13. GeeksforGeeks. Vision Transformer (ViT) Architecture - GeeksforGeeks. GeeksforGeeks. URL: <https://www.geeksforgeeks.org/vision-transformer-vit-architecture/>.
14. Ashish Vaswani. Attention Is All You Need. 2017, arXiv.org. URL: <https://arxiv.org/abs/1706.03762>.
15. A Survey on Transfer Learning. IEEE Xplore. URL: <https://ieeexplore.ieee.org/document/5288526>.
16. GitHub - tensorflow/tensorflow: An Open Source Machine Learning

- Framework for Everyone. *GitHub*. URL: <https://github.com/tensorflow/tensorflow>
17. GitHub - ashushekar/VGG16. *GitHub*. URL: <https://github.com/ashushekar/VGG16>
18. Chest X-ray (Covid-19 & Pneumonia) URL: <https://www.kaggle.com/datasets/prashant268/chest-xray-covid19-pneumonia>
19. Очікується публікація статті(посилання поки відсутнє)
20. Западенко К.О. Використання ші для ранньої діагностики онкологічних захворювань. // Науково-практична конференція «Проблеми комп'ютерної інженерії». Київ: ДУІКТ, (очікую публікації)
21. Западенко К.О. ADA HEALTH та штучний інтелект: переваги використання чат-бота для покращення якості медичних консультацій. // Науково-практична конференція «Проблеми комп'ютерної інженерії». Київ: ДУІКТ, (очікую публікації)

## Приклад діагностики знімків для виявлення COVID-19




Рисунок А.1 – Приклад класифікація рентгенівських знімків за допомогою ШІ для виявлення COVID-19




Рисунок А.2 – Приклад класифікація КТ-знімків за допомогою ШІ для виявлення COVID-19



Рисунок А. 3 – Рентгенівський знімок легень здорової людини



Рисунок А.4 - Рентгенівський знімок легень з COVID-19



Рисунок А.5 – Рентгенівський знімок легень з пневмонією

## Структура CNN




Рисунок Б.1 – Вигляд архітектури CNN



Рисунок Б.2 – Діагностика Covid-19 з методом Grad-CAM **ResNet** –  
вихідне положення




Рисунок Б.3 – Діагностика Covid-19 з методом Grad-CAM **ResNet** –  
Grad-CAM



Рисунок Б.3 - Діагностика Covid-19 з методом Grad-CAM **DenseNet** –  
вихідне положення




Рисунок Б.4 - Діагностика Covid-19 з методом Grad-CAM **DenseNet** –  
Grad-CAM




Рисунок Б.5 – Приклад класифікації зображень виявлення COVID-19, пневмонія за допомогою ViT




Рисунок Б.6 – Структура мережі VGG-16




Рисунок 2. 7 – Зображення архітектури VGG-16




Рисунок Б.8 – Приклад класифікації зображень X-Ray у використанні VGG-16

```

from tensorflow.keras.optimizers import Adam

model.compile(optimizer=Adam(), loss='categorical_crossentropy', metrics=['accuracy'])
    
```

Рисунок Б.9 – Використання Adam

```

model.fit(x_train, y_train, epochs=10, batch_size=32, validation_data=(x_val, y_val))
    
```

Рисунок Б.10 – Базовий приклад використання методу fit()

```

test_loss, test_accuracy = model.evaluate(x_test, y_test)
    
```

Рисунок Б.11 - приклад використання методу evaluate()

Дані для розробки класифікації




Рисунок В.1 – Набір даних з 3 категоріями




Рисунок В.2 – Набір тестовий та навчальний

### Available models

| Model             | Size   | Top-1 Accuracy | Top-5 Accuracy | Parameters  | Depth |
|-------------------|--------|----------------|----------------|-------------|-------|
| Inception         | 88 MB  | 0.790          | 0.945          | 22,910,480  | 120   |
| VGG16             | 528 MB | 0.713          | 0.901          | 138,357,544 | 23    |
| VGG19             | 549 MB | 0.713          | 0.900          | 143,657,240 | 26    |
| ResNet50          | 98 MB  | 0.749          | 0.921          | 25,636,712  | -     |
| ResNet101         | 171 MB | 0.784          | 0.928          | 44,707,128  | -     |
| ResNet152         | 232 MB | 0.766          | 0.931          | 90,419,944  | -     |
| ResNet20V2        | 98 MB  | 0.760          | 0.930          | 23,613,800  | -     |
| ResNet101V2       | 171 MB | 0.772          | 0.938          | 44,675,560  | -     |
| ResNet152V2       | 232 MB | 0.780          | 0.942          | 80,380,548  | -     |
| InceptionV3       | 92 MB  | 0.779          | 0.947          | 31,051,764  | 154   |
| InceptionResNetV2 | 215 MB | 0.803          | 0.953          | 55,873,756  | 272   |
| MobileNet         | 16 MB  | 0.704          | 0.895          | 4,253,804   | 88    |
| MobileNetV2       | 14 MB  | 0.711          | 0.901          | 3,500,404   | 101   |
| DenseNet121       | 74 MB  | 0.750          | 0.923          | 6,087,504   | 121   |
| DenseNet169       | 57 MB  | 0.782          | 0.942          | 14,307,100  | 164   |
| DenseNet201       | 80 MB  | 0.773          | 0.936          | 20,242,984  | 201   |
| NASNetMobile      | 25 MB  | 0.744          | 0.919          | 3,326,716   | -     |
| NASNetLarge       | 343 MB | 0.825          | 0.960          | 88,849,018  | -     |
| EfficientNetB0    | 29 MB  | -              | -              | 5,330,571   | -     |
| EfficientNetB1    | 31 MB  | -              | -              | 7,856,230   | -     |
| EfficientNetB2    | 36 MB  | -              | -              | 9,177,560   | -     |
| EfficientNetB3    | 48 MB  | -              | -              | 12,320,535  | -     |
| EfficientNetB4    | 75 MB  | -              | -              | 19,486,823  | -     |
| EfficientNetB5    | 118 MB | -              | -              | 30,562,527  | -     |
| EfficientNetB6    | 166 MB | -              | -              | 43,265,143  | -     |
| EfficientNetB7    | 256 MB | -              | -              | 66,658,687  | -     |

Рисунок В.3 – Попередньо навчені моделі у модулі Keras Application

### Продовження Додатка В

| Назва моделі      | Точність (%) | Помилка (%) |
|-------------------|--------------|-------------|
| VGG16             | 97.5         | 2.5         |
| ResNet152V2       | 94.2         | 5.8         |
| DenseNet201       | 92.7         | 7.3         |
| InceptionResNetV2 | 95.0         | 5.0         |

Таблиця В.1 - Використання попередньо навчених моделей і їх тестування на точність та помилковість

```
base_model = VGG16(weights='imagenet', include_top=False, input_shape=(224, 224, 3))
```

Рисунок В.4 – Завантаження попередньо навченої моделі




Рис. В.5 – Динаміка точності тренування та валідації




Рис. В.6 – Динаміка втрати тренування та валідації

| Layer (type)                     | Output Shape          | Param # |
|----------------------------------|-----------------------|---------|
| input_1 (InputLayer)             | (None, 224, 224, 3)   | 0       |
| block1_conv1 (Conv2D)            | (None, 224, 224, 64)  | 1792    |
| block1_conv2 (Conv2D)            | (None, 224, 224, 64)  | 36928   |
| block1_pool (MaxPooling2D)       | (None, 112, 112, 64)  | 0       |
| block2_conv1 (Conv2D)            | (None, 112, 112, 128) | 73856   |
| block2_conv2 (Conv2D)            | (None, 112, 112, 128) | 147584  |
| block2_pool (MaxPooling2D)       | (None, 56, 56, 128)   | 0       |
| block3_conv1 (Conv2D)            | (None, 56, 56, 256)   | 295168  |
| block3_conv2 (Conv2D)            | (None, 56, 56, 256)   | 590080  |
| block3_conv3 (Conv2D)            | (None, 56, 56, 256)   | 590080  |
| block3_pool (MaxPooling2D)       | (None, 28, 28, 256)   | 0       |
| block4_conv1 (Conv2D)            | (None, 28, 28, 512)   | 1180160 |
| block4_conv2 (Conv2D)            | (None, 28, 28, 512)   | 2359808 |
| block4_conv3 (Conv2D)            | (None, 28, 28, 512)   | 2359808 |
| block4_pool (MaxPooling2D)       | (None, 14, 14, 512)   | 0       |
| block5_conv1 (Conv2D)            | (None, 14, 14, 512)   | 2359808 |
| block5_conv2 (Conv2D)            | (None, 14, 14, 512)   | 2359808 |
| block5_conv3 (Conv2D)            | (None, 14, 14, 512)   | 2359808 |
| block5_pool (MaxPooling2D)       | (None, 7, 7, 512)     | 0       |
| flatten_1 (Flatten)              | (None, 25088)         | 0       |
| dense_1 (Dense)                  | (None, 128)           | 3211392 |
| dense_2 (Dense)                  | (None, 1)             | 129     |
| Total params: 17,926,209         |                       |         |
| Trainable params: 3,211,521      |                       |         |
| Non-trainable params: 14,714,688 |                       |         |

Рисунок В.7 – Вигляд архітектури




Рисунок В.8 – Результат класифікації зображень( COVID-19/NORMAL)

| Метод                      | Кількість зображень, що аналізуються | Час аналізу (на зображення) | Точність (правильні відповіді)          |
|----------------------------|--------------------------------------|-----------------------------|-----------------------------------------|
| Виявлення за допомогою ШІ  | 1 000 зображень                      | 1-2 секунди                 | 92% (понад 90% у багатьох дослідженнях) |
| Традиційний людський огляд | 1 000 зображень                      | 10-20 хвилин                | 80-85%                                  |

Таблиця В.2 - Порівняння методів аналізу рентгенівського зображення для виявлення COVID-19

## Код для розробки класифікації зображень

*# Завантаження необхідних бібліотек*

```
import os
import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import VGG16
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, Flatten, Dropout
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
from tensorflow.keras.preprocessing import image
```

*# Налаштування параметрів*

```
IMAGE_SIZE = (224, 224)
BATCH_SIZE = 32
EPOCHS = 30
LEARNING_RATE = 0.0001
```

*# Шлях до датасету*

```
TRAIN_DIR = "path/to/train/dataset"
VAL_DIR = "path/to/validation/dataset"
TEST_DIR = "path/to/test/dataset"
```

*# Генератори даних*

```
train_datagen = ImageDataGenerator(
    rescale=1.0/255,
    rotation_range=20,
    width_shift_range=0.2,
    height_shift_range=0.2,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True
)

val_datagen = ImageDataGenerator(rescale=1.0/255)

test_datagen = ImageDataGenerator(rescale=1.0/255)

train_generator = train_datagen.flow_from_directory(
    TRAIN_DIR,
    target_size=IMAGE_SIZE,
    batch_size=BATCH_SIZE,
```

```
class_mode='categorical'
)
```

```
val_generator = val_datagen.flow_from_directory(
    VAL_DIR,
    target_size=IMAGE_SIZE,
    batch_size=BATCH_SIZE,
    class_mode='categorical'
)
```

```
test_generator = test_datagen.flow_from_directory(
    TEST_DIR,
    target_size=IMAGE_SIZE,
    batch_size=BATCH_SIZE,
    class_mode='categorical',
    shuffle=False
)
```

```
# Завантаження попередньо навченої моделі VGG-16
```

```
base_model = VGG16(weights='imagenet', include_top=False, input_shape=(224, 224,
3))
```

```
# Замороження ваг базової моделі
```

```
base_model.trainable = False
```

```
# Додавання власного класифікатора
```

```
x = Flatten()(base_model.output)
```

```
x = Dense(256, activation='relu')(x)
```

```
x = Dropout(0.5)(x)
```

```
x = Dense(128, activation='relu')(x)
```

```
x = Dropout(0.5)(x)
```

```
x = Dense(2, activation='softmax')(x) # 2 класи: COVID-19, Normal
```

```
model = Model(inputs=base_model.input, outputs=x)
```

```
# Компіляція моделі
```

```
model.compile(
    optimizer=Adam(learning_rate=LEARNING_RATE),
    loss='categorical_crossentropy',
    metrics=['accuracy']
)
```

```
# Вивід структури моделі
```

```
model.summary()
```

*# Налаштування зупинки та збереження найкращої моделі*

```
early_stopping = EarlyStopping(monitor='val_loss', patience=7,
restore_best_weights=True)
model_checkpoint = ModelCheckpoint('best_model.h5', monitor='val_loss',
save_best_only=True)
```

*# Навчання моделі*

```
history = model.fit(
    train_generator,
    validation_data=val_generator,
    epochs=EPOCHS,
    callbacks=[early_stopping, model_checkpoint]
)
```

*# Оцінка на тестових даних*

```
test_loss, test_accuracy = model.evaluate(test_generator)
print(f"Test Accuracy: {test_accuracy * 100:.2f}%")
```

*# Побудова графіків точності та втрат*

```
plt.figure(figsize=(12, 6))
```

```
plt.subplot(1, 2, 1)
plt.plot(history.history['accuracy'], label='Train Accuracy')
plt.plot(history.history['val_accuracy'], label='Validation Accuracy')
plt.title('Accuracy')
plt.xlabel('Epochs')
plt.ylabel('Accuracy')
plt.legend()
```

```
plt.subplot(1, 2, 2)
plt.plot(history.history['loss'], label='Train Loss')
plt.plot(history.history['val_loss'], label='Validation Loss')
plt.title('Loss')
plt.xlabel('Epochs')
plt.ylabel('Loss')
plt.legend()
```

```
plt.tight_layout()
plt.show()
```

*# Збереження фінальної моделі*

```
model.save('final_covid_classifier.h5')
```

*# Класифікація нового зображення*

```
def classify_image(img_path, model):  
    img = image.load_img(img_path, target_size=IMAGE_SIZE)  
    img_array = image.img_to_array(img) / 255.0  
    img_array = np.expand_dims(img_array, axis=0)  
    prediction = model.predict(img_array)  
    class_idx = np.argmax(prediction)  
    class_labels = ["COVID-19", "NORMAL"] # Оновлені класи  
    return class_labels[class_idx], img
```

*# Приклад використання*

```
sample_image_path = "path/to/sample_image.jpg"  
result, img = classify_image(sample_image_path, model)
```

*# Вивід зображення з результатом*

```
plt.figure(figsize=(6, 6))  
plt.imshow(img)  
plt.title(f"Classification Result: {result}")  
plt.axis('off')  
plt.show()
```