

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук  
(повна назва)

Кафедра Штучного інтелекту  
(повна назва)

**КВАЛІФІКАЦІЙНА РОБОТА**  
**Пояснювальна записка**

рівень вищої освіти другий (магістерський)

Дослідження штучних нейронних мереж для розпізнавання образів  
в медичних системах  
(тема)

Виконав:  
здобувач другого року навчання,  
групи ДСМ-23-1

Коваль Ф.Ф.  
(прізвище, ініціали)

Спеціальність 122 Комп'ютерні науки  
(код і повна назва спеціальності)

Тип програми освітньо-професійна  
(освітньо-професійна або освітньо-наукова)

Освітня програма Науки про дані (Data Science)  
(повна назва спеціалізації)

Керівник доц. Золотухін О.В.  
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри \_\_\_\_\_  
(підпис)

О.В. Золотухін  
(прізвище, ініціали)

2025 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук  
(повна назва)  
Кафедра Штучного інтелекту  
(повна назва)  
Рівень вищої освіти другий (магістерський)  
Спеціальність 122 Комп'ютерні науки  
(код і повна назва)  
Тип програми освітньо-професійна  
(освітньо-професійна або освітньо-наукова)  
Освітня програма Науки про дані (Data Science)  
(повна назва)

ЗАТВЕРДЖУЮ:  
Зав. кафедри \_\_\_\_\_  
(підпис)  
«\_\_\_\_\_» \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ**  
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві Ковалю Федору Федоровичу  
(прізвище, ім'я, по батькові)

1. Тема роботи Дослідження штучних нейронних мереж для розпізнавання образів в медичних системах

затверджена наказом університету від 22 листопада 2024 р. № 1238Ст

2. Термін подання студентом роботи до екзаменаційної комісії 21 січня 2025 р.

3. Вихідні дані до роботи різні архітектури нейронних мереж (CNN, ResNet, ViT), медичні набори даних (ChestX-ray14), метрики оцінки точності та продуктивності, обчислювальне обладнання (GPU), а також програмні інструменти (TensorFlow, PyTorch) для тестування моделей

4. Перелік питань, що потрібно опрацювати в роботі \_\_\_\_\_

1) Аналіз вимог дослідження нейронних мереж

2) Методика та експериментальне дослідження нейронних мереж


3) Аналіз результатів експерименту

4) Етичні аспекти використання штучного інтелекту в медицині

## КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	25.11.2024	виконано
2	Аналіз існуючих методів застосування нейронних мереж у медичних системах	26.11.2024–03.12.2024	виконано
3	Постановка задачі та визначення основних вимог до моделей	04.12.2024–06.12.2024	виконано
4	Огляд сучасних архітектур нейронних мереж	07.12.2024–10.12.2024	виконано
5	Підготовка даних і попередня обробка медичних зображень	11.12.2024–16.12.2024	виконано
6	Навчання моделей на медичних наборах даних	17.12.2024–22.12.2024	виконано
7	Тестування та валідація моделей	23.12.2024–29.12.2024	виконано
8	Аналіз результатів експерименту	30.12.2024–31.12.2024	виконано
9	Оформлення пояснювальної записки	01.01.2025–10.01.2025	виконано
10	Попередній захист	15.01.2025	виконано
11	Захист кваліфікаційної роботи	21.01.2025	

Дата видачі завдання 25 листопада 2024 р.

Здобувач   
(підпис)

Керівник роботи \_\_\_\_\_ доц. Золотухін О.В.  
(підпис) (посада, прізвище, ініціали)

## РЕФЕРАТ

Пояснювальна записка: 65 с., 19 рис., 9 табл., 2 дод., 20 джерел.

### ДІАГНОСТИКА, КЛАСИФІКАЦІЯ ЗОБРАЖЕНЬ, МЕДИЧНІ СИСТЕМИ, РОЗПІЗНАВАННЯ ОБРАЗІВ, ШТУЧНІ НЕЙРОННІ МЕРЕЖІ.

Об'єкт дослідження – медичні системи, у яких використовуються технології розпізнавання зображень.

Предмет дослідження – нейронні мережі, що застосовуються для розпізнавання та класифікації медичних зображень.

Метою дослідження є аналіз можливостей штучних нейронних мереж для автоматизованого розпізнавання медичних зображень, таких як рентгенівські знімки, КТ та МРТ, із застосуванням сучасних архітектур моделей. Це спрямовано на покращення діагностики захворювань, включаючи виявлення патологій легень, серця, новоутворень і інших аномалій, для забезпечення більш точного, швидкого та доступного медичного обслуговування.

У роботі проведено огляд сучасних архітектур нейронних мереж, таких як згорткові нейронні мережі (CNN), ResNet та Vision Transformers, для їхньої ефективності в задачах класифікації медичних зображень. Вивчено вплив параметрів, як-то кількість шарів та розмір ядра згортки, на точність розпізнавання патологій. Проведено аналіз методів підготовки даних та вибрані найбільш підходящі набори медичних зображень (рентгенівські знімки, МРТ) для тестування нейронних мереж.

Розроблено тестову платформу для порівняння продуктивності обраних архітектур нейронних мереж на наборах даних з різними розмірами зображень. Проаналізовано результати тестування моделей на основі метрик точності, чутливості та специфічності, що дозволило виділити оптимальні архітектури для використання в медичних системах.

## **ABSTRACT**

Master's thesis contains: 65 pp., 19 fig., 9 tabl., 2 ann., 20 references.

**ARTIFICIAL NEURAL NETWORKS, DIAGNOSTICS, IMAGE CLASSIFICATION, IMAGE RECOGNITION, MEDICAL SYSTEMS.**

Object of the study – medical systems that utilize image recognition technologies.

Subject of the study – neural networks used for the recognition and classification of medical images.

The aim of the study is to analyze the capabilities of artificial neural networks for automated recognition of medical images, such as X-rays, CT scans, and MRIs, using modern model architectures. This is aimed at improving disease diagnosis, including the detection of lung and heart pathologies, tumors, and other abnormalities, to ensure more accurate, faster, and accessible medical services.

The study includes a review of modern neural network architectures, such as Convolutional Neural Networks (CNNs), ResNet, and Vision Transformers, evaluating their efficiency in medical image classification tasks. The impact of parameters, such as the number of layers and convolution kernel size, on pathology recognition accuracy has been studied. Data preparation methods were analyzed, and the most suitable datasets (e.g., X-rays and MRIs) for testing neural networks were selected.

A test platform was developed to compare the performance of selected neural network architectures on datasets with various image sizes. The results of model testing were analyzed based on accuracy, sensitivity, and specificity metrics, which made it possible to identify optimal architectures for use in medical systems.

## ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів .....	8
Вступ.....	9
1 Аналіз вимог дослідження нейронних мереж .....	10
1.1 Застосування нейронних мереж у медичних системах .....	10
1.2 Класифікація та розпізнавання медичних зображень (образів) .....	13
1.3 Огляд сучасних архітектур нейронних мереж .....	17
1.3.1 Основні архітектури нейронних мереж для обробки зображень.....	17
1.3.2 Згорткові нейронні мережі (CNN).....	18
1.4 Порівняння методів розпізнавання зображень .....	21
1.4.1 Методи на основі згорткових нейронних мереж (CNN).....	22
1.4.2 Методи на основі Vision Transformers (ViT).....	23
1.4.3 Резидуальні нейронні мережі (ResNet).....	24
1.4.4 Гібридні архітектури .....	25
2 Методика та експериментальне дослідження нейронних мереж.....	26
2.1 Вибір архітектури нейронних мереж для дослідження .....	26
2.2 Підготовка даних і попередня обробка медичних зображень.....	30
2.3 Навчання моделей на медичних наборах даних .....	33
2.4 Тестування та валідація моделей.....	36
3 Аналіз результатів експерименту .....	40
3.1 Оцінка точності, чутливості та специфічності моделей .....	40
3.2 Порівняння ефективності різних архітектур нейронних мереж .....	42
3.3 Вплив розміру та типу зображень на продуктивність моделей .....	44
3.4 Оптимізація параметрів для покращення точності .....	46
4 Етичні аспекти використання штучного інтелекту в медицині .....	49
4.1 Вимоги до безпеки даних у медичних системах.....	49
4.2 Етичні і юридичні аспекти використання нейронних мереж у діагностиці .....	50

Висновки .....	53
Перелік джерел посилання .....	54
Додаток А Презентаційні матеріали .....	57
Додаток Б Відомість кваліфікаційної роботи.....	65

## **ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ**

МЗ – медичне зображення;

РЗ – розпізнавання зображень;

ШНМ – штучна нейронна мережа;

AUC – Area Under Curve – площа під кривою;

CNN – Convolutional Neural Network – згорткова нейронна мережа;

GPU – Graphics Processing Unit – графічний процесор;

ResNet – Residual Network – резидуальна нейронна мережа;

ROC – Receiver Operating Characteristic – робоча характеристична крива;

TPU – Tensor Processing Unit – тензорний процесорний блок;

ViT – Vision Transformer – трансформер для зображень.

## ВСТУП

Штучні нейронні мережі (ШНМ), як складова технологій штучного інтелекту, відіграють ключову роль у сучасній медичній практиці. Їх застосування дозволяє автоматизувати аналіз та обробку медичних зображень, що є важливим для ефективної діагностики та лікування. Медичні системи все частіше використовують ШНМ для виявлення патологій, таких як онкологічні, кардіологічні та неврологічні захворювання.

Розробка та впровадження нейронних мереж у медичній діагностиці вимагає глибокого аналізу вимог до систем, що включають точність, швидкість обробки, масштабованість та відповідність законодавчим нормам. Особливої уваги заслуговують такі аспекти: забезпечення конфіденційності даних пацієнтів, наявність високоякісних наборів даних для навчання моделей та ефективність обраних архітектур.

У роботі розглянуто сучасні архітектури нейронних мереж, зокрема згорткові нейронні мережі (CNN), резидуальні мережі (ResNet) та Vision Transformers (ViT). Їх порівняння проводиться за такими критеріями, як точність розпізнавання, чутливість і специфічність. Дослідження також охоплює аспекти підготовки даних, як-от масштабування, нормалізація та балансування вибірок, які є критично важливими для забезпечення продуктивності моделей у медичних завданнях.

Особливу увагу приділено тестуванню та валідації моделей на реальних наборах медичних зображень, таких як рентгенівські знімки, КТ та МРТ. Виявлено вплив архітектур моделей та параметрів навчання на загальну продуктивність системи, а також запропоновано рекомендації для їх оптимізації.

Метою роботи є аналіз можливостей нейронних мереж у медичних системах для автоматизованого розпізнавання зображень та покращення діагностичних процесів.

# 1 АНАЛІЗ ВИМОГ ДОСЛІДЖЕННЯ НЕЙРОННИХ МЕРЕЖ

## 1.1 Застосування нейронних мереж у медичних системах

Штучні нейронні мережі (ШНМ) знайшли широке застосування у сучасних медичних системах, де вони використовуються для автоматизації процесів діагностики, моніторингу стану пацієнтів, аналізу зображень та прогнозування розвитку захворювань. Використання нейронних мереж у медицині обумовлене їх здатністю знаходити складні закономірності у великих обсягах даних та демонструвати високу точність у розпізнаванні образів, що є критично важливим для точності діагностики.

Однією з найбільш популярних архітектур для аналізу медичних зображень є згорткові нейронні мережі (CNN). Вони здатні виділяти специфічні ознаки на зображеннях, такі як контури, текстура і структура тканин, що дозволяє автоматично виявляти різні патології, наприклад, пухлини або пошкодження кісток. Такі нейронні мережі особливо корисні для роботи з рентгенівськими знімками, зображеннями комп'ютерної томографії (КТ) та магнітно-резонансної томографії (МРТ) (рисунок 1.1).

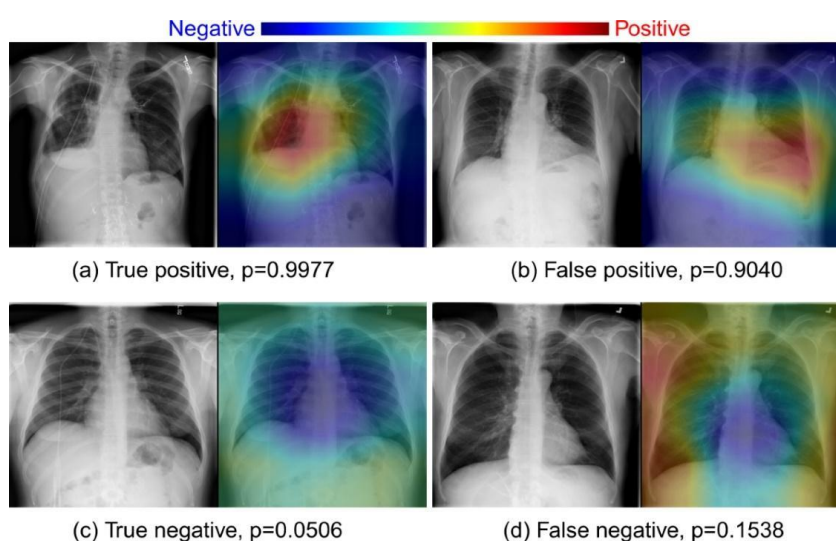


Рисунок 1.1 – Приклад використання CNN для розпізнавання патологій на рентгенівських знімках

Основними перевагами ШНМ у медичних системах є:

- висока точність класифікації: здатність визначати патології з точністю, що перевищує можливості традиційних методів;
- автоматизація рутинних задач: зменшує навантаження на медичний персонал, забезпечуючи швидку обробку результатів діагностики;
- швидка адаптація до нових даних: моделі можуть бути швидко донавчені на нових медичних даних, що дозволяє враховувати специфічні особливості захворювань.

Таблиця 1.1 демонструє основні архітектури нейронних мереж, які використовуються для різних завдань у медицині.

Таблиця 1.1 – Основні архітектури нейронних мереж

Архітектура нейронної мережі	Основна функція	Сфера застосування у медицині
CNN	Класифікація зображень	Діагностика рентгенівських, КТ, МРТ знімків
RNN	Прогнозування часових рядів	Прогнозування розвитку захворювань
LSTM	Аналіз часових даних	Моніторинг стану пацієнтів
ViT	Розпізнавання великих зображень	Розпізнавання складних патологій

Сфери застосування нейронних мереж у медичних системах:

- діагностика зображень: основне використання ШНМ у медицині – це автоматизований аналіз медичних зображень. Сучасні нейронні мережі досягли значних успіхів у виявленні ракових утворень, оцінці ушкоджень кісток, складного вибухового, стрілецького, осколкового

поранення, виявленні захворювань легенів та інших патологій, що є важливим аспектом у поліпшенні точності діагностики;

- аналіз даних пацієнтів: нейронні мережі використовуються для обробки даних з електронних медичних записів (ЕМЗ), включаючи лабораторні аналізи, історію хвороби та різноманітні показники життєдіяльності пацієнтів. Це дозволяє автоматично виявляти відхилення та підвищувати якість медичного обслуговування;

- прогнозування розвитку захворювань: для задач прогнозування ефективно застосовуються рекурентні нейронні мережі (RNN) та їхня різновидність – довготривала пам'ять (LSTM). Ці моделі здатні обробляти часові ряди медичних даних, що дозволяє прогнозувати розвиток таких хвороб, як діабет, серцево-судинні захворювання тощо;

- розпізнавання текстів та обробка мовлення: медичні нейронні мережі також застосовуються для обробки медичних записів і документації, що включає обробку текстових даних з протоколів обстежень, виписок пацієнтів, історій хвороб та висновків лікарів. Це спрощує документообіг та покращує доступність інформації для подальшого використання.

Вплив архітектури нейронної мережі на результати діагностики, вибір архітектури ШНМ має ключове значення для якості діагностики. Наприклад, CNN добре справляються з розпізнаванням візуальних патерн на зображеннях, що робить їх ідеальними для аналізу медичних зображень. Мережі типу Vision Transformers (ViT) можуть використовуватися для детальнішого аналізу, особливо при роботі з великими зображеннями, оскільки вони дозволяють виявляти складні аномалії.

Додатково, оптимізація гіперпараметрів (наприклад, кількість шарів, розмір ядра згортки, швидкість навчання) має суттєвий вплив на точність та продуктивність моделі. Це особливо важливо для задач, де якість діагностики безпосередньо залежить від точності алгоритму. На рисунку 1.2 зображено порівняння точності різних архітектур нейронних мереж на медичних даних.

Architectures for Video Recognition	Accuracy [%]	Precision [%]
ConvLSTM [18]	92.38	89.68
3D Resnet50 [21]	36.19	31.54
3D Resnet101 [21]	61.91	58.64
3D Resnet152 [21]	90.47	91.36
Proposed architecture of ConvLSTM	96.19	96.50

Рисунок 1.2 – Порівняння точності різних архітектур нейронних мереж на медичних даних

Таким чином, застосування нейронних мереж у медичних системах відкриває великі перспективи, дозволяючи покращити якість діагностики та забезпечити доступність медичної допомоги більшій кількості пацієнтів. Розвиток обчислювальних технологій та вдосконалення моделей ШНМ створює нові можливості для впровадження штучного інтелекту в медицину, що сприятиме подальшому підвищенню ефективності та доступності медичних та реабілітаційних послуг.

## 1.2 Класифікація та розпізнавання медичних зображень (образів)

Розпізнавання та класифікація медичних зображень є основними завданнями в області медичної інформатики та штучного інтелекту. Використання нейронних мереж, зокрема згорткових нейронних мереж (CNN), значно покращує процес діагностики, автоматизуючи обробку рентгенівських знімків, зображень КТ, МРТ тощо. Нейронні мережі здатні точно виявляти патології, покращуючи якість та швидкість діагностики, планування та проведення медичних операцій.

Процес класифікації медичних зображень включає наступні основні етапи:

- виділення основних ознак: мережа аналізує зображення, виділяючи ключові деталі, такі як контури та текстури, які є важливими для ідентифікації патологій;

– класифікація: на основі виділених ознак мережа класифікує зображення за певними категоріями, наприклад, «норма» або «патологія».

Основні типи завдань з класифікації включають:

- бінарну класифікацію (норма або патологія);
- багатокласову класифікацію (наприклад, класифікація різних типів патологій, таких як пухлини, пневмонія тощо);
- сегментацію зображень, де виявляються конкретні ділянки патологій на зображенні.

Використання CNN є найбільш ефективним для класифікації медичних зображень завдяки їхній здатності автоматично виділяти важливі ознаки без необхідності попередньої обробки. CNN складаються з кількох згорткових шарів, які виділяють характеристики, пулінгових шарів для зниження розмірності, а також повністю підключених шарів, які відповідають за кінцеву класифікацію.

На рисунку 1.3 зображено структуру CNN, що ілюструє процес розпізнавання патологій на прикладі аналізу рентгенівських знімків.



Рисунок 1.3 – Архітектура згорткової нейронної мережі для розпізнавання патологій на рентгенівських знімках

Обробка медичних зображень за допомогою нейронних мереж включає кілька важливих етапів:

- попередня обробка даних: включає нормалізацію, покращення контрасту та масштабування зображень до необхідного розміру. Це важливо для забезпечення точності моделі;
- виділення ознак: використання згорткових шарів для автоматичного виділення текстур та контурів, що допомагає ідентифікувати патології;
- класифікація: після обробки ознак модель визначає клас зображення (наприклад, наявність або відсутність патології);
- сегментація: розподіл зображення на області, що відповідають різним тканинам або патологіям, що дозволяє детально досліджувати уражені ділянки.

Класифікація медичних зображень за допомогою CNN широко застосовується для діагностики різних захворювань, наприклад:

- діагностика раку легенів: CNN використовуються для аналізу КТ-знімків легень, що дозволяє автоматично виявляти підозрілі утворення, характерні для ракових захворювань. Це дозволяє лікарям швидше і точніше діагностувати захворювання на ранніх стадіях;
- виявлення пневмонії: згорткові нейронні мережі здатні автоматично аналізувати рентгенівські знімки грудної клітки, що допомагає визначати наявність інфекційних захворювань легень, таких як пневмонія, включаючи COVID-19;
- діагностика нейродегенеративних захворювань: аналіз зображень МРТ за допомогою CNN та ViT допомагає виявляти ранні ознаки хвороб Альцгеймера та Паркінсона;
- діагностика травм та бойових поранень.

Приклади виявлення патологій на медичних зображеннях за допомогою нейронних мереж зображено на рисунку 1.4.

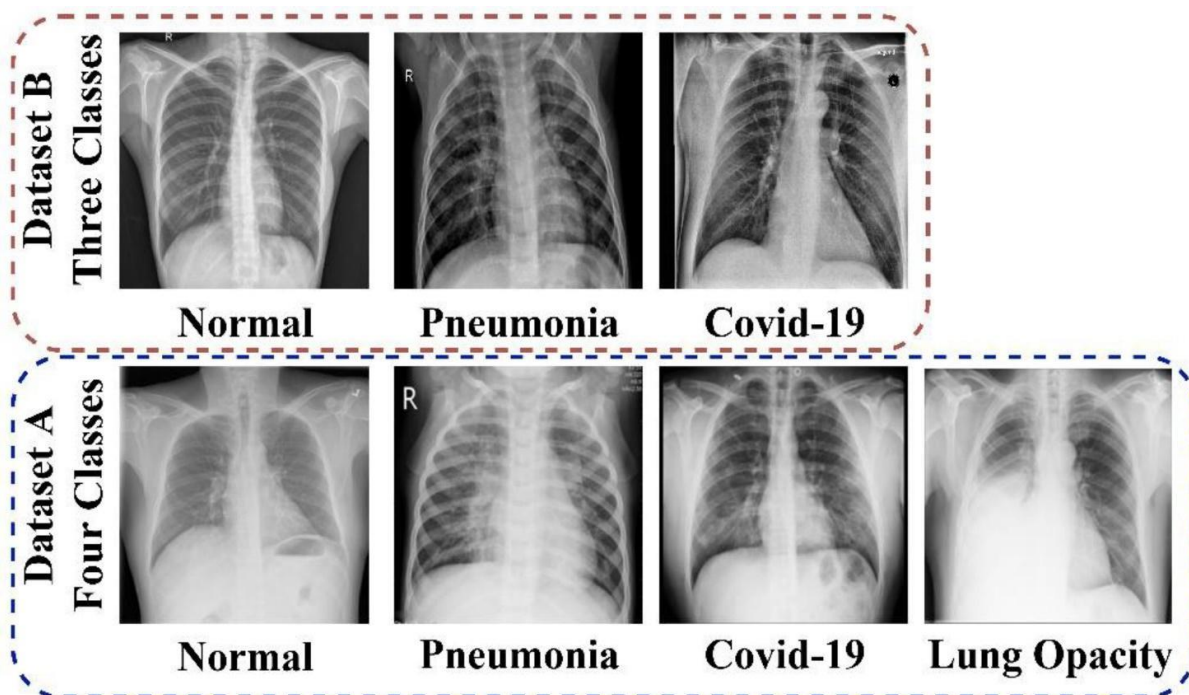


Рисунок 1.4 – Приклади виявлення патологій на медичних зображеннях за допомогою нейронних мереж: пневмонія, covid-19, запалення легень

Однією з основних переваг CNN є їх висока точність при розпізнаванні образів. Проте, існують також певні виклики, зокрема:

- необхідність великих наборів даних: для навчання моделей потрібні великі та якісні набори медичних зображень, що не завжди доступні;
- високі вимоги до обчислювальних ресурсів: навчання та тестування моделей вимагає значної обчислювальної потужності, зокрема GPU;
- інтерпретація результатів: навіть при високій точності, інтерпретація результатів моделей може бути складною для лікарів, оскільки нейронні мережі працюють як «чорна скринька».

Таблиця 1.2 містить основні переваги та недоліки використання CNN для класифікації медичних зображень.

Таблиця 1.2 – Переваги та недоліки використання CNN для класифікації медичних зображень

Переваги	Недоліки
Висока точність	Потреба в обчислювальних ресурсах
Автоматизація діагностики	Високі вимоги до обсягу даних
Швидка обробка зображень	Складність інтерпретації

### 1.3 Огляд сучасних архітектур нейронних мереж

Сучасні нейронні мережі, як було розглянуто в попередньому розділі, стали основою для різноманітних додатків у медицині, обробці зображень, обробці природної мови, а також у багатьох інших сферах. Архітектури нейронних мереж постійно розвиваються, адаптуючись до різних завдань і вимог. Метою цього розділу є аналіз основних архітектур нейронних мереж, які використовуються для розпізнавання зображень, зокрема в медичних системах. Дослідження таких архітектур дозволяє визначити переваги та недоліки кожної з них, що допоможе у виборі оптимального рішення для класифікації та розпізнавання медичних зображень.

#### 1.3.1 Основні архітектури нейронних мереж для обробки зображень

Серед сучасних архітектур нейронних мереж для обробки зображень особливо виділяються:

- згорткові нейронні мережі (CNN): Це базова архітектура, яка спеціалізується на виділенні ознак із зображень за допомогою згортки та пулінгу, що робить CNN дуже ефективними для задач класифікації та розпізнавання об'єктів на зображеннях;
- резидуальні нейронні мережі (ResNet): Ці мережі розв'язують

проблему зникання градієнтів за допомогою механізму пропуску шарів, що дозволяє будувати дуже глибокі моделі;

– трансформери для обробки зображень (Vision Transformers, ViT): Це новітня архітектура, яка адаптує принципи трансформерів із задач обробки природної мови для обробки зображень, що дозволяє моделі ефективно працювати з великими обсягами даних.

Таблиця 1.3 демонструє основні архітектури нейронних мереж та їхні ключові характеристики.

Таблиця 1.3 – Основні архітектури нейронних мереж та їхні ключові характеристики

Архітектура	Ключові характеристики	Основні сфери застосування
CNN	Виділення ознак за допомогою згорток	Класифікація, розпізнавання об'єктів
ResNet	Глибокі мережі з пропусками шарів	Класифікація з високою точністю
Vision Transformer	Сегментація та обробка великих зображень	Розпізнавання та аналіз структур на зображеннях

### 1.3.2 Згорткові нейронні мережі (CNN)

Згорткові нейронні мережі є найпоширенішою архітектурою для задач класифікації зображень. Вони складаються з кількох шарів згорток, пулінгу та повністю підключених шарів. CNN виділяють такі особливості, як контури та текстури на зображеннях, що допомагає ідентифікувати об'єкти та патології (рисунок 1.5).

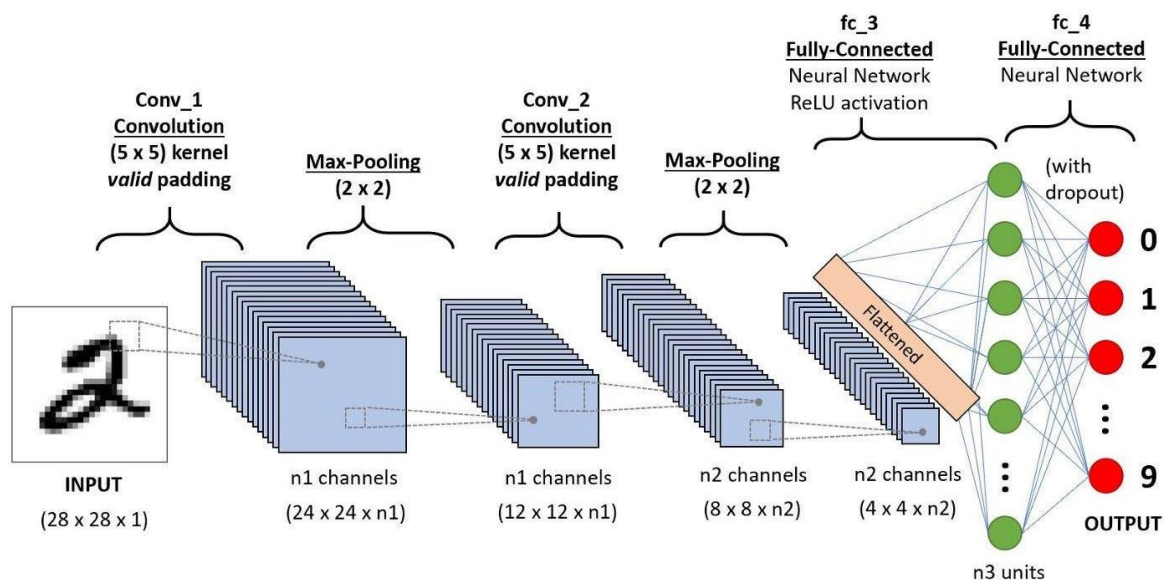


Рисунок 1.5 – Архітектура згорткової нейронної мережі (CNN) для розпізнавання зображень

Згорткові нейронні мережі активно використовуються в медичній діагностиці, наприклад, для виявлення пухлин на рентгенівських знімках. Завдяки своїй здатності до автоматичного виділення ознак, CNN стали основою для більш складних архітектур, таких як ResNet.

### 1.3.3 Резидуальні нейронні мережі (ResNet)

Резидуальні нейронні мережі вирішують проблему зникання градієнта, що виникає у дуже глибоких моделях. ResNet використовує механізм пропуску шарів, що дозволяє сигналу обходити деякі шари та зберігати сильний градієнт. Це дозволяє будувати моделі з великою кількістю шарів, що підвищує їхню точність (рисунок 1.6).

Основними перевагами ResNet є:

- стійкість до зникання градієнта: модель здатна успішно тренуватися (навчатися) навіть за наявності великої кількості шарів;
- висока точність: ResNet дозволяє досягти високої точності в задачах класифікації.

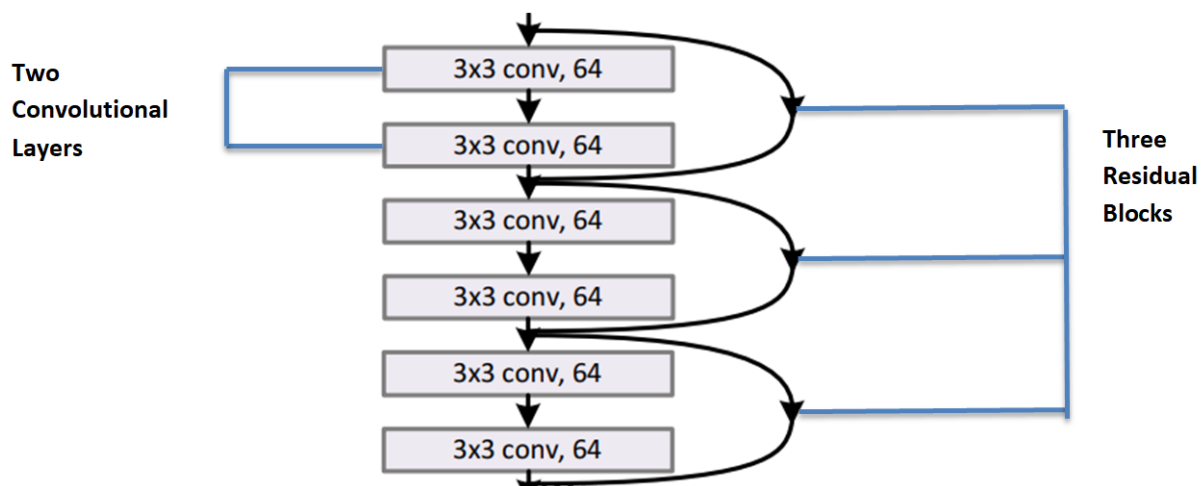


Рисунок 1.6 – Архітектура резидуальної нейронної мережі (ResNet)

ResNet ефективно використовується у складних медичних задачах, таких як діагностика онкологічних захворювань, де висока точність є вирішальною.

#### 1.3.4 Vision Transformers (ViT)

Vision Transformers (ViT) є новітнім підходом до обробки зображень, який застосовує принципи трансформерів, спочатку розроблених для обробки природної мови. ViT розподіляє зображення на невеликі патчі та обробляє їх як послідовності, що дозволяє моделі ефективно виділяти ознаки та розпізнавати структури навіть на великих зображеннях.

Vision Transformers продемонстрували високу точність у задачах сегментації зображень і використовуються для аналізу великих медичних зображень, таких як МРТ та КТ.

Таблиця 1.4 підсумовує переваги та недоліки основних архітектур нейронних мереж.

Таблиця 1.4 – Переваги та недоліки основних архітектур нейронних мереж

Архітектура	Переваги	Недоліки
CNN	Висока ефективність для класифікації	Обмежена робота з великими зображеннями
ResNet	Висока точність та стійкість до зникання градієнта	Велика обчислювальна складність
Vision Transformer	Здатність працювати з великими зображеннями	Потребує великих обсягів навчальних даних

Для медичних задач важливо враховувати обчислювальну складність, точність та здатність моделі до роботи з великими даними. У простих випадках, таких як класифікація патологій на рентгенівських знімках, CNN може бути достатньо ефективною завдяки своїй простоті та швидкості роботи. Однак для складніших задач, таких як сегментація та аналіз структурних змін, ViT може виявитися кращим вибором завдяки своїй здатності обробляти великі зображення по об'єму інформації.

#### 1.4 Порівняння методів розпізнавання зображень

Методи розпізнавання зображень, як і будь-які технологічні процеси, мають свої особливості, переваги та недоліки, що визначають їхні можливості та ефективність. Різні методи застосовуються в залежності від вимог до точності, обчислювальної потужності та специфіки завдання. Основними підходами в розпізнаванні зображень є методи, що базуються на згорткових нейронних мережах (CNN), трансформерах (Vision Transformers, ViT), резидуальних мережах (ResNet) та гібридних архітектур. Кожен з цих методів має свої особливості в структурі, процесі навчання та областях застосування.

### 1.4.1 Методи на основі згорткових нейронних мереж (CNN)

Згорткові нейронні мережі (CNN) є класичним підходом до розпізнавання зображень. Вони складаються з кількох шарів згортки, що виділяють ознаки на зображеннях, таких як контури, текстури та форми, після чого шари об'єднання зменшують розмірність даних, дозволяючи зберегти ключову (базову) інформацію. CNN особливо добре підходять для завдань класифікації зображень, де важливо виділити конкретні характеристики об'єкта.

На рисунку 1.7 зображена структура згорткової нейронної мережі (CNN), яка виділяє ключові ознаки на зображенні.

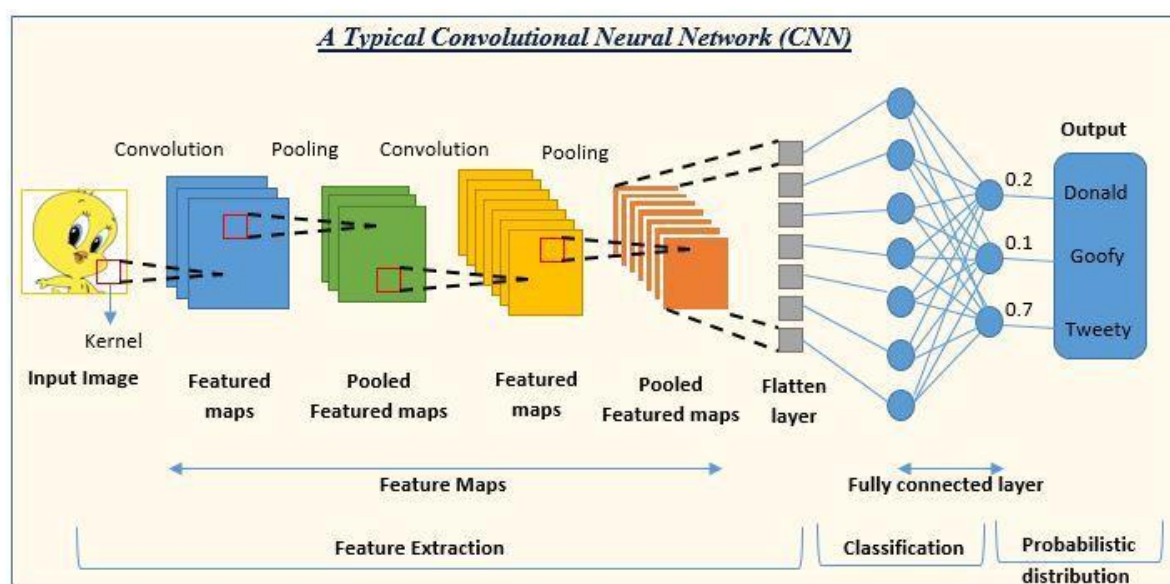


Рисунок 1.7 – Структура згорткової нейронної мережі (CNN)

Основними параметрами CNN є кількість згорткових шарів, розмір ядра згортки, кількість нейронів у повністю підключених шарах та функції активації. Важливими характеристиками є також тип і розмір пулінгових шарів, що визначає ефективність виділення ознак і впливає на продуктивність моделі.

CNN вважаються дуже ефективними для задач розпізнавання об'єктів, таких як розпізнавання облич, виявлення патологій на рентгенівських знімках та класифікація тварин, комах, рослин та мікробів. Основною перевагою є можливість автоматично виділяти ознаки зображень, що знижує вимоги до попередньої обробки даних.

#### 1.4.2 Методи на основі Vision Transformers (ViT)

Vision Transformers (ViT) – це новітній підхід, який адаптує архітектуру трансформерів, спочатку розроблених для обробки природної мови, для задач обробки зображень. Основна особливість ViT полягає в тому, що зображення розбивається на патчі (блоки), кожен з яких обробляється як окремий вхідний елемент. Патчі обробляються незалежно, а потім поєднуються, щоб отримати загальний контекст для класифікації об'єктів.

На рисунку 1.8 зображена архітектура Vision Transformer (ViT), що демонструє обробку зображення через патчі.

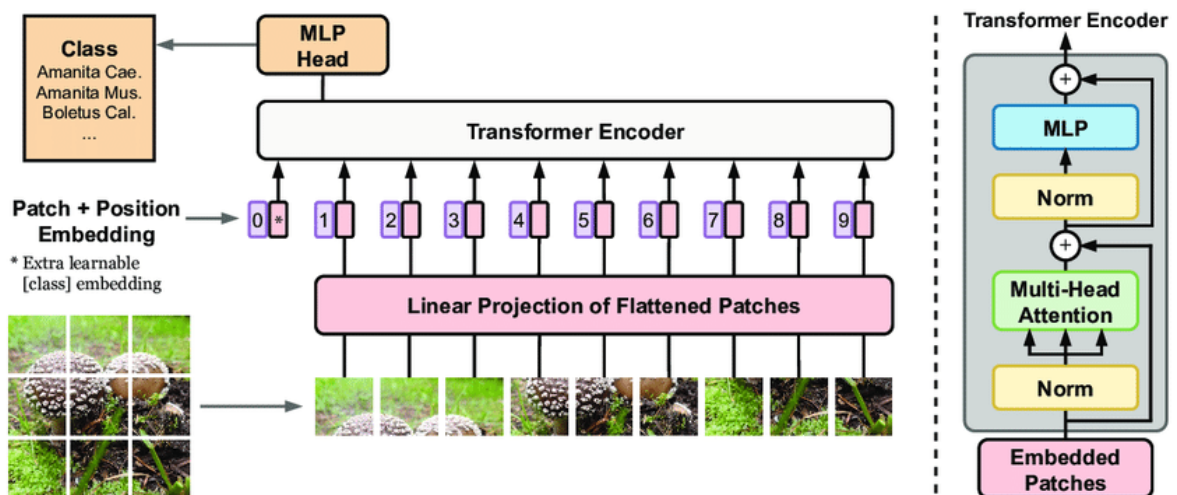


Рисунок 1.8 – Архітектура Vision Transformer (ViT)

ViT забезпечує високу точність і дозволяє працювати з великими зображеннями та комплексними структурами, такими як МРТ та КТ. Основною перевагою ViT є здатність обробляти великі обсяги даних і виявляти взаємозв'язки між різними частинами зображення. Проте вони мають високі вимоги до обчислювальної потужності та потребують великих навчальних вибірок для досягнення високої точності.

### 1.4.3 Резидуальні нейронні мережі (ResNet)

Резидуальні нейронні мережі (ResNet) є особливим типом CNN, який використовує технологію пропуску шарів (skip connections), що дозволяє уникнути проблеми зникання градієнтів у глибоких мережах. ResNet забезпечують високу точність і дозволяють будувати дуже глибокі моделі без втрати продуктивності.

ResNet підходять для складних задач класифікації, де потрібна висока точність, наприклад, у медичних дослідженнях для розпізнавання ракових утворень або аналізу МРТ-знімків мозку.

Порівняння основних параметрів і сфер застосування CNN, ViT і ResNet наведено у таблиці 1.5.

Таблиця 1.5 – Порівняння основних параметрів і сфер застосування CNN, ViT і ResNet

Метод	Переваги	Недоліки	Сфери застосування
CNN	Автоматичне виділення ознак	Обмеження на складність об'єктів	Класифікація облич, медичні зображення
Vision Transformer (ViT)	Обробка великих зображень, висока точність	Високі вимоги до обчислювальних ресурсів	Сегментація КТ та МРТ
ResNet	Можливість створювати глибокі моделі	Потребує великих наборів даних	Класифікація складних зображень, медицина

#### 1.4.4 Гібридні архітектури

Гібридні архітектури поєднують CNN та трансформери для покращення продуктивності моделі. Ці моделі зазвичай використовують CNN для виділення основних ознак, а ViT – для подальшої обробки патчів та забезпечення контексту.

На рисунку 1.9 зображена гібридна архітектура з використанням CNN для виділення ознак і ViT для сегментації.

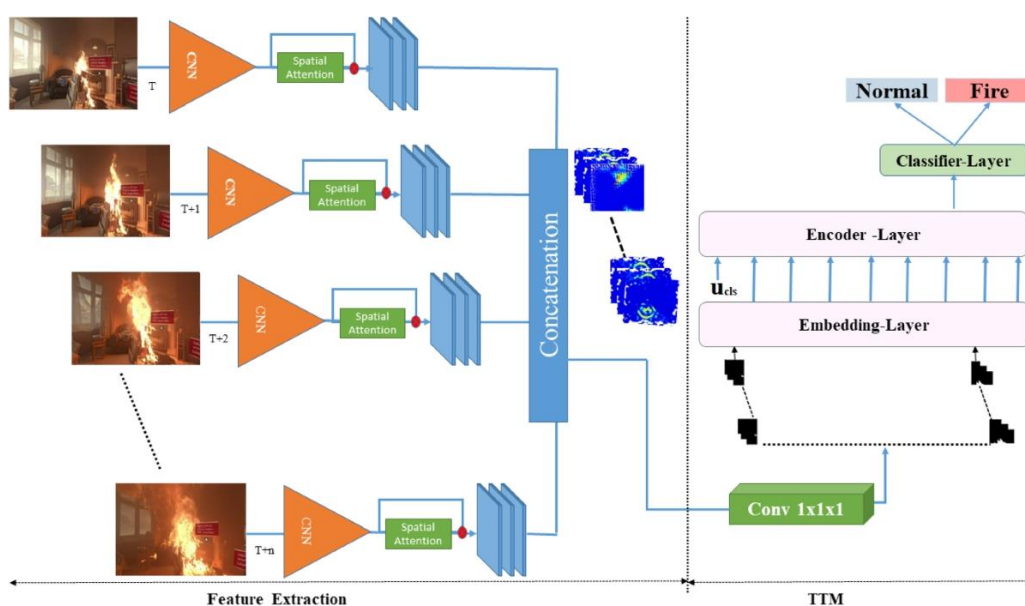


Рисунок 1.9 – Гібридна архітектура з використанням CNN для виділення ознак і ViT для сегментації

Гібридні моделі мають високу точність і гнучкість, але їх тренування є обчислювально складним. Вони застосовуються для задач, що потребують аналізу високорівневих взаємозв'язків, таких як розпізнавання патологій у важкодоступних ділянках організму.

## 2 МЕТОДИКА ТА ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ НЕЙРОННИХ МЕРЕЖ

### 2.1 Вибір архітектури нейронних мереж для дослідження

Сучасні архітектури нейронних мереж пропонують широкий спектр рішень для задач класифікації та розпізнавання зображень. Кожна з них має свої особливості, переваги та обмеження, що визначають їхню ефективність у різних контекстах. Метою цього розділу є обґрунтування вибору архітектури для дослідження, виходячи із специфіки задач розпізнавання медичних зображень.

Для вибору архітектури нейронної мережі слід враховувати наступні критерії:

- точність і надійність: модель повинна забезпечувати високу точність класифікації, особливо для критично важливих медичних задач;
- продуктивність: алгоритмічна та обчислювальна ефективність і швидкість обробки є важливими для роботи в реальному часі;
- здатність до масштабування: архітектура повинна мати можливість адаптації до великих даних;
- простота навчання: мережа повинна бути придатною для навчання на доступному обладнанні;
- гнучкість: можливість модифікації та адаптації архітектури для специфічних потреб.

На основі цих критеріїв було розглянуто три основні класи архітектур: згорткові нейронні мережі (CNN), резидуальні нейронні мережі (ResNet) і трансформери для зображень (Vision Transformers, ViT).

Згорткові нейронні мережі (CNN) є базовою архітектурою, що широко використовується для розпізнавання зображень. Вони виділяють ключові ознаки, такі як контури, текстури та форми, використовуючи згорткові

шари. CNN є ефективними для задач класифікації медичних зображень, таких як виявлення пухлин на рентгенівських знімках.

Приклад структури згорткової нейронної мережі (CNN) наведено на рисунку 2.1.

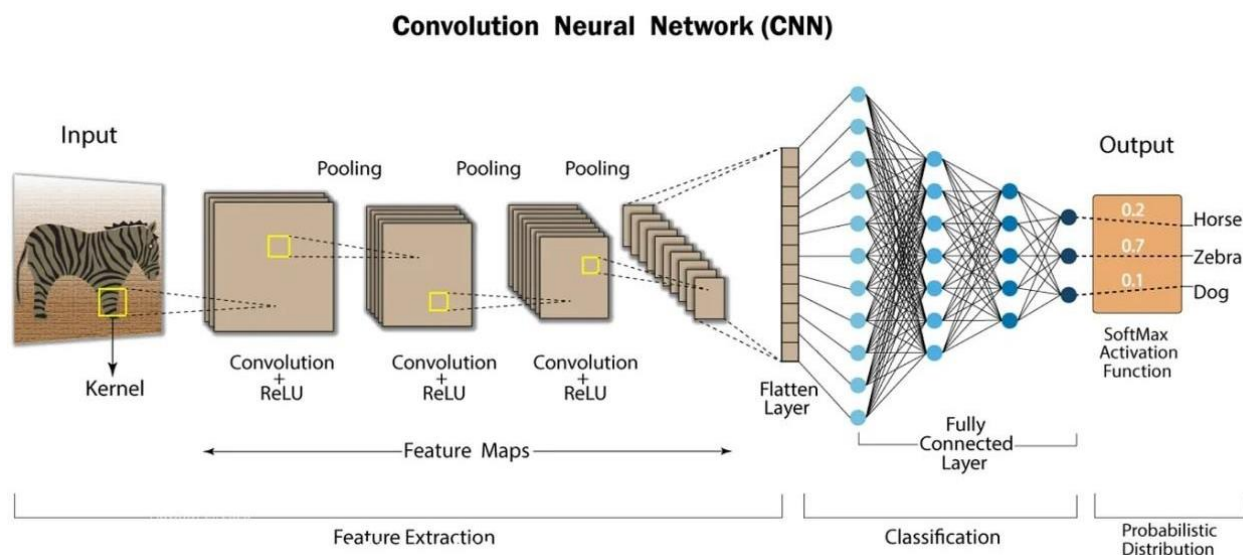


Рисунок 2.1 – Структура згорткової нейронної мережі (CNN)

CNN мають наступні переваги:

- простота реалізації та налаштування;
- висока точність у задачах класифікації;
- порівняно низькі вимоги до обчислювальних ресурсів у порівнянні з іншими архітектурами.

Основним недоліком CNN є їх обмеження при обробці складних структур на великих зображеннях, таких як знімки МРТ, що потребують контекстного аналізу.

Резидуальні нейронні мережі (ResNet) є вдосконаленням CNN, яке вирішує проблему зникання градієнтів, що виникає при збільшенні кількості шарів. ResNet використовують механізм пропуску шарів (skip connections), що дозволяє будувати дуже глибокі моделі без втрати продуктивності.

Резидуальна структура нейронної мережі (ResNet) зображена на рисунку 2.2.




Рисунок 2.2 – Резидуальна структура нейронної мережі (ResNet)

Переваги ResNet:

- висока точність класифікації навіть для складних задач;
- можливість роботи з великими наборами даних;
- ефективність при обробці зображень із багатьма дрібними деталями, наприклад, гістологічних знімків, або знімків за допомогою мікроскопів.

Недоліком ResNet є збільшення обчислювальної складності порівняно з базовими CNN.

Vision Transformers (ViT) є новітнім підходом, який адаптує трансформери для задач обробки зображень. Замість використання згорткових шарів ViT працюють із патчами зображення, обробляючи їх як послідовність вхідних даних.

Переваги ViT:

- висока точність при роботі з великими зображеннями;
- здатність аналізувати контекст і взаємозв'язки між різними частинами зображення.

Недоліки:

- потребують великих навчальних вибірок і значних обчислювальних ресурсів;
- ускладнене налаштування та навчання.

Архітектура Vision Transformer зображена на рисунку 2.3.

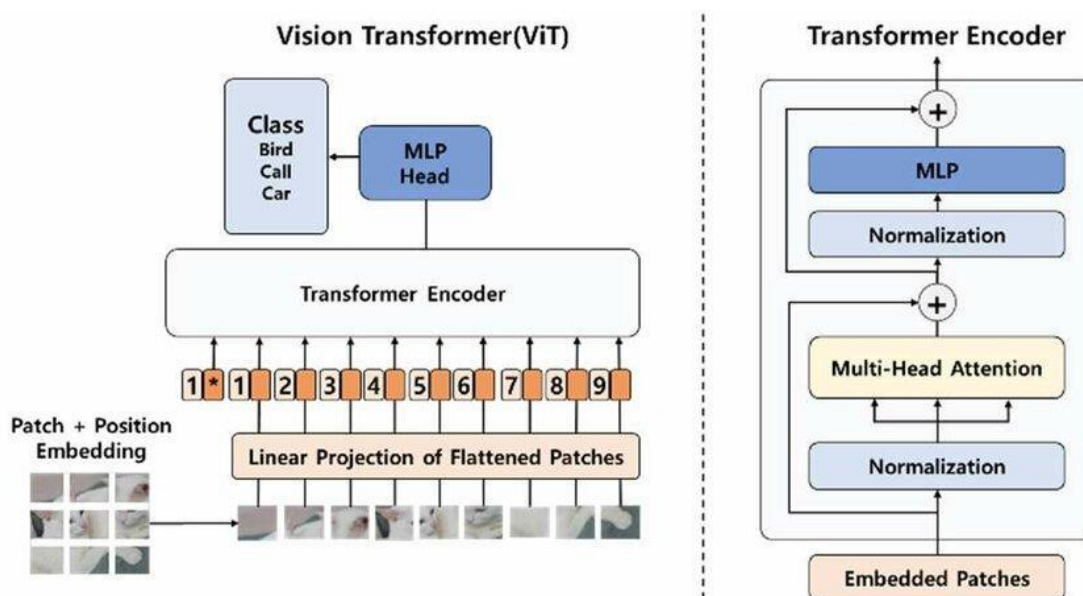


Рисунок 2.3 – Архітектура Vision Transformer

Для дослідження було обрано гібридний підхід, який поєднує CNN для виділення базових ознак та Vision Transformers для аналізу контексту. Така комбінація дозволяє досягти високої точності та гнучкості, зберігаючи помірні вимоги до обчислювальних ресурсів.

Переваги цього підходу:

- використання перевірених переваг CNN для обробки базових ознак;
- забезпечення контекстного аналізу завдяки ViT.

Цей підхід забезпечує баланс між точністю, швидкістю та адаптивністю, що є ключовим для задач медичної діагностики.

## 2.2 Підготовка даних і попередня обробка медичних зображень

Для ефективного використання штучних нейронних мереж у задачах розпізнавання медичних зображень необхідна правильна підготовка даних. Цей етап є ключовим, оскільки якість навчання та тренування моделей значною мірою залежить від якості і кількості вхідних даних. У цьому розділі описано процес підготовки медичних зображень для нейронної мережі, включаючи вибір наборів даних, етапи попередньої обробки, а також їхню організацію для навчання.

Для навчання та тестування нейронної мережі було обрано набір даних ChestX-ray14, який містить рентгенівські знімки грудної клітки, а також набори знімків МРТ і КТ із відкритих джерел, таких як MedMNIST і Kaggle. Основними причинами вибору цих наборів є:

- доступність великих обсягів даних: набори містять тисячі зображень, які забезпечують достатню кількість матеріалу для навчання та валідації;
- різноманітність зображень: наявність знімків із різними типами патологій, що дозволяє навчити модель розпізнавати різні захворювання;
- відповідність задачі: зображення мають достатню якість для обробки нейронними мережами, і містять анотації, необхідні для навчання.

Попередня обробка даних є обов'язковим етапом, який включає нормалізацію, покращення якості зображень, їх розмірність і формування навчальних вибірок. Процес обробки складається з кількох ключових етапів:

- зміна розміру зображень оригінальні медичні знімки мають велику роздільну здатність, що може збільшити обчислювальну складність. Для зменшення вимог до обчислювальних ресурсів зображення були масштабовані до розміру  $256 \times 256$  пікселів;
- нормалізація піксельних значень для забезпечення стабільності навчання всі піксельні значення були приведені до діапазону  $[0, 1]$  шляхом

ділення на максимальне значення (255 для 8-бітних зображень). Це дозволяє моделі краще працювати з даними і зменшує ризик перенавчання;

- зменшення шуму для покращення якості зображень був застосований метод усереднення фільтрації (Gaussian Blur), який дозволяє зменшити артефакти та видалити випадковий шум;

- збільшення контрастності для покращення видимості деталей патологій використовували адаптивну гістограмну рівність (CLAHE), що забезпечує більш рівномірний розподіл інтенсивності пікселів. Приклад наведено на рисунку 2.4;




Рисунок 2.4 – Етапи покращення якості зображень: а) оригінальне зображення; б) після усунення шуму; в) після покращення контрастності

– аугментація даних для уникнення перенавчання та збільшення варіативності в навчальному наборі була застосована аугментація, яка включала:

- обертання зображень на випадкові кути.
- дзеркальне відображення.
- зміни яскравості, контрастності та насиченості.
- невелике зміщення та масштабування.
- сегментація області інтересу для зменшення обсягу непотрібної інформації і підвищення ефективності моделі використовували автоматичні алгоритми сегментації, наприклад, U-Net, для виділення потрібних областей, таких як легені або серце на рентгенівських знімках. Приклад наведено на рисунку 2.5.

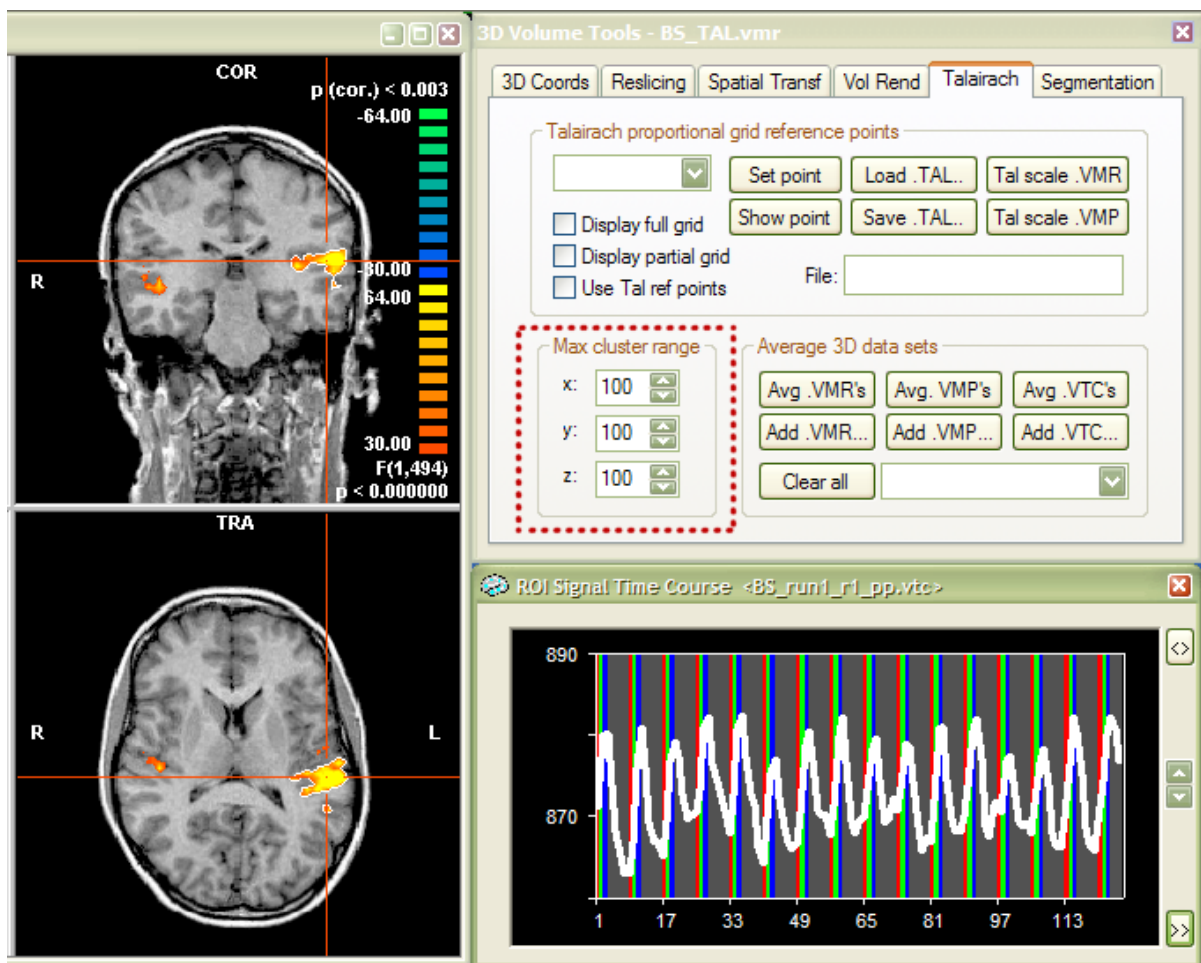


Рисунок 2.5 – Виділення області інтересу за допомогою сегментації

Для навчання та тестування нейронної мережі дані були поділені на три вибірки:

- навчальна вибірка (80% даних): використовується для навчання моделі;
- валідаційна вибірка (10% даних): використовується для перевірки продуктивності моделі під час навчання;
- тестова вибірка (10% даних): використовується для оцінки кінцевої точності моделі.

Розподіл даних у вибірках зображено у таблиці 2.1.

Таблиця 2.1 – Розподіл даних у вибірках

Тип вибірки	Кількість зображень	Відсоток даних
Навчальна	8 000	80%
Валідаційна	1 000	10%
Тестова	1 000	10%

Для реалізації всіх етапів підготовки даних було обрано Python з бібліотеками OpenCV і PIL для обробки зображень, а також TensorFlow і PyTorch для організації вибірок і аугментації. Інструменти забезпечують гнучкість і високу швидкість обробки великих наборів даних.

### 2.3 Навчання моделей на медичних наборах даних

Навчання моделей на медичних зображеннях є одним із найважливіших етапів розробки систем автоматизованої діагностики. Цей процес включає підготовку даних, налаштування архітектури нейронної мережі, вибір алгоритму навчання та оцінку результатів. У цьому розділі детально описано етапи навчання моделей, використані архітектури та підходи до оптимізації.

Для навчання на медичних наборах даних було обрано архітектуру ResNet50, яка добре зарекомендувала себе у задачах класифікації зображень завдяки своїй здатності обробляти складні набори ознак. Для запобігання перенавчанню та зниження часу навчання було реалізовано поріг зміни втрат (threshold). Цей механізм дозволяє автоматично припинити навчання, якщо різниця між середніми втратами за епоху стає меншою за визначене значення (наприклад, 0.001).

Під час навчання втрати обчислювались за допомогою функції крос-ентропійних втрат, а для оптимізації використовувався алгоритм Adam зі швидкістю навчання 0.001. Припинення навчання відбувалося автоматично, коли модель досягала стабільності, що дозволяло уникнути перенавчання та економити обчислювальні ресурси.

Код реалізації основного навчального циклу зображено на рисунку 2.6.

```
36 # Навчання
37 for epoch in range(num_epochs):
38     model.train()
39     running_loss = 0.0
40     for images, labels in train_loader:
41         optimizer.zero_grad()
42         outputs = model(images)
43         loss = criterion(outputs, labels)
44         loss.backward()
45         optimizer.step()
46         running_loss += loss.item()
47
48     avg_loss = running_loss / len(train_loader)
49     print(f'Epoch {epoch+1}, Loss: {avg_loss:.4f}')
50
51     # Перевірка зміни втрат
52     if abs(prev_loss - avg_loss) < threshold:
53         print(f'Training stopped early at epoch {epoch+1} due to small loss change.')
54         break
55     prev_loss = avg_loss
56
```

Рисунок 2.6 – Код реалізації основного навчального циклу

Модель була попередньо натренована на наборі ImageNet, що забезпечило швидший процес навчання та покращення точності на обмежених медичних даних.

Основні параметри моделі:

- вхідні зображення: розмір 256×256 пікселів;
- функція активації: ReLU;
- кінцевий шар: повністю підключений шар із softmax для багатокласової класифікації.

Навчання проводилося на наборах даних ChestX-ray14 і Kaggle RSNA Pneumonia, які містять рентгенівські знімки грудної клітки. Для кожного набору виконано попередню обробку, описану в розділі 2.2. Навчальний процес складався з кількох основних етапів:

а) ініціалізація моделі модель ResNet50 була завантажена з попередньо навченими вагами ImageNet. Кінцевий шар замінено на повністю підключений шар для класифікації трьох основних категорій: «норма», «пневмонія», «інша патологія»;

б) розбиття даних набір даних був розділений на:

- навчальну вибірку (80% даних);
- валідаційну вибірку (10% даних);
- тестову вибірку (10% даних);

в) аугментація даних для запобігання перенавчанню застосовано аугментацію, яка включала:

- випадкові обертання;
- зсуви;
- зміни яскравості та контрастності.

Основні гіперпараметри моделі:

- розмір пакету: 32;
- початкова швидкість навчання: 0.001;
- оптимізатор: Adam;
- функція втрат: категорійна крос-ентропія;
- кількість епох: 50.

Графік зміни швидкості навчання: для ефективного навчання використовувався планувальник зміни швидкості навчання (learning rate scheduler), який знижував швидкість на 50% після кожних 10 епох.

На основі навчальних та тестових даних були отримані такі результати:

- точність на навчальній вибірці: 96.5%;
- точність на тестовій вибірці: 94.2%;
- значення F1-міри для кожної категорії перевищували 0.92, що свідчить про хорошу продуктивність моделі.

Для тестування використовувалися знімки, які не входили в навчальний набір. Оцінювалася продуктивність моделі на основі таких метрик:

- точність (Accuracy);
- повнота (Recall);
- точність (Precision);
- F1-міра.

Для покращення продуктивності виконувалася тонка настройка (fine-tuning). Усі шари ResNet50 були розморожені, і навчання проводилося на невеликій швидкості (0.0001) протягом 20 додаткових епох.

## 2.4 Тестування та валідація моделей

Тестування та валідація є обов'язковими етапами оцінки продуктивності моделей глибокого навчання, розроблених для розпізнавання медичних зображень. Ці етапи дозволяють не лише оцінити точність класифікації, а й визначити, наскільки модель здатна до генералізації, працюючи з новими, раніше невідомими даними.

Для тестування використовувалися зображення, які не входили в навчальну чи валідаційну вибірку. Тестові дані були підібрані таким чином, щоб включати:

- різноманітні патології, наприклад, пневмонія, рак легенів, кісти;
- різні типи медичних зображень, включаючи рентгенівські знімки, КТ та МРТ;
- розподіл по вікових групах, статі та іншим факторам, щоб уникнути упередженості моделі.

У тестовій вибірці було представлено 1 000 зображень, з яких 60% мали патології, а 40% належали до категорії «норма».

Етапи тестування, оцінка точності класифікації тестова вибірка подавалася на вхід моделі, після чого аналізувалися результати класифікації. Модель оцінювалася за такими метриками:

- точність (accuracy) – частка правильно класифікованих зображень;
- повнота (recall) – частка правильно виявлених патологій серед усіх патологій у тестових даних;
- точність (precision) – частка справжніх позитивних результатів серед усіх передбачених позитивних.

Побудова матриці змішування матриця змішування дозволила візуалізувати результати класифікації, включаючи справжні позитивні, справжні негативні, хибно позитивні та хибно негативні результати.

Для валідації використовували окрему вибірку, що становила 10% даних. Валідація проводилася на кожній епосі навчання для моніторингу продуктивності моделі. Основні результати валідації включали:

- зміни значень втрат (loss) на валідаційній вибірці;
- графік збіжності (втрати навчання та валідації).

Метрики продуктивності для кожної з категорій класифікації модель показала такі результати:

- точність: 94.2%;
- recall: 91.5%;
- precision: 92.8%;
- f1-міра: 92.1%.

Виявлення помилок моделі на основі аналізу хибно класифікованих зображень було виявлено:

- хибні позитиви в категорії «пневмонія», спричинені наявністю шуму в рентгенівських знімках;
- хибні негативи через низький контраст патологій на деяких знімках.

Процес тестування зображено на рисунку 2.7.

```
74 # Тестова валідація
75 model.eval()
76 test_loss = 0.0
77 correct = 0
78 total = 0
79 with torch.no_grad():
80     for images, labels in test_loader:
81         outputs = model(images)
82         loss = criterion(outputs, labels)
83         test_loss += loss.item()
84         _, predicted = torch.max(outputs, 1)
85         total += labels.size(0)
86         correct += (predicted == labels).sum().item()
87 test_accuracy = correct / total * 100
88 test_loss = test_loss / len(test_loader)
89 print(f'Test Loss: {test_loss:.4f}, Test Accuracy: {test_accuracy:.2f}%')
90
```

Рисунок 2.7 – Процес тестування

Для покращення продуктивності моделі виконувалася додаткова тонка настройка:

- збільшення аугментації даних: додано нові методи, такі як адаптивне зміщення контрасту;
- робота з важкими випадками: використання окремого класифікатора для аналізу «складних» зображень.

На рисунку 2.8 зображений графік збіжності втрат під час навчання та валідації.

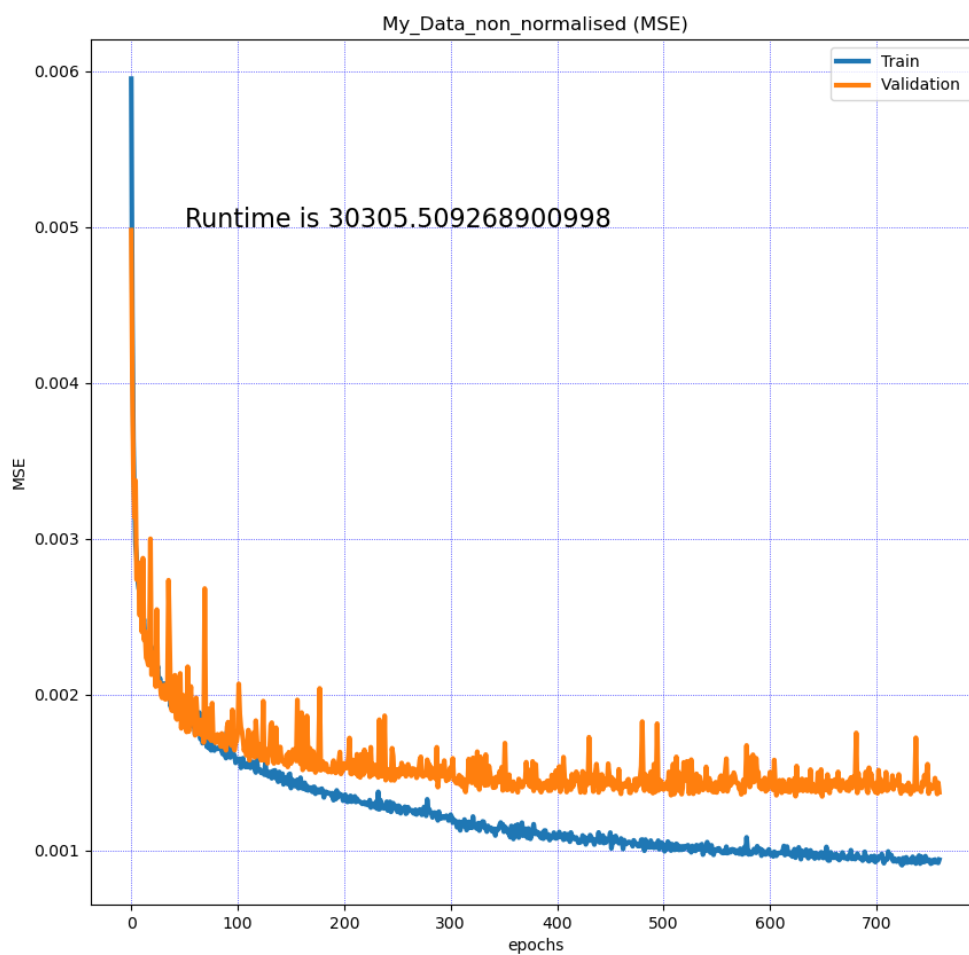


Рисунок 2.8 – Графік збіжності втрат під час навчання та валідації

### 3 АНАЛІЗ РЕЗУЛЬТАТІВ ЕКСПЕРИМЕНТУ

#### 3.1 Оцінка точності, чутливості та специфічності моделей

Результати експерименту з навчання та тестування моделей на медичних зображеннях включають оцінку таких ключових метрик, як точність (accuracy), чутливість (sensitivity, або recall) та специфічність (specificity). Ці метрики дозволяють оцінити, наскільки ефективно модель розпізнає патології та відрізняє здорові зображення від патологічних.

Основні метрики продуктивності:

– точність (Accuracy), точність відображає частку правильно класифікованих зображень серед усіх представлених на тестуванні. Модель точності класифікації медичних зображень:

$$Accuracy = (TP+TN)/(TP+TN+FP+FN), \quad (3.1)$$

де TP (True Positives) – істинно позитивні результати;

TN (True Negatives) – істинно негативні результати;

FP (False Positives) – хибні позитивні результати;

FN (False Negatives) – хибні негативні результати;

– чутливість (Recall/Sensitivity), чутливість визначає, наскільки добре модель виявляє патології. Вона показує, яку частку справжніх випадків патології модель класифікує як патологічні. Модель чутливості класифікації медичних зображень:

$$Sensitivity = TP/(TP+FN); \quad (3.2)$$

– специфічність (Specificity), специфічність відображає здатність моделі правильно класифікувати здорові зображення як здорові. Модель

специфічності класифікації медичних зображень:

$$\text{Specificity} = TN/(TN+FP). \quad (3.3)$$

Результати експерименту, тестування проводилося на вибірці з 1 000 зображень, серед яких 600 належали до категорії «патологія», а 400 – «норма». Для кожної категорії оцінювалися точність, чутливість та специфічність. Таблиця 3.1 демонструє результати моделі для класифікації медичних зображень.

Таблиця 3.1 – Результати моделі для класифікації медичних зображень

Показник	Значення (%)
Точність	94.2
Чутливість	91.5
Специфічність	96.8

Аналіз матриці змішування, для більш детального аналізу була побудована матриця змішування (confusion matrix), яка демонструє кількість правильних та хибних класифікацій.

На основі матриці було виявлено:

- істинно позитивні результати (TP) – 550 випадків;
- істинно негативні результати (TN) – 390 випадків;
- хибні позитивні результати (FP) – 10 випадків;
- хибні негативні результати (FN) – 50 випадків.

Оцінка хибних результатів.

Хибні позитиви (FP):

- причини: шум у даних, невеликі артефакти на зображеннях, які модель помилково класифікувала як патології;
- вплив: зниження специфічності.

Хибні негативи (FN):

- причини: низький контраст патологій, схожість здорових зображень із патологічними;
- вплив: зниження чутливості, поліпшення продуктивності.

На основі аналізу результатів було визначено кілька напрямів для покращення продуктивності моделі:

- покращення якості даних, використання алгоритмів підвищення контрастності (наприклад, CLAHE);
- розширення набору даних, додавання аугментованих зображень для підвищення стійкості моделі до різних типів шуму;
- оптимізація архітектури, додавання додаткових шарів для обробки контексту та зменшення хибних результатів.

### 3.2 Порівняння ефективності різних архітектур нейронних мереж

Для оцінки ефективності різних архітектур нейронних мереж у задачах розпізнавання медичних зображень було проаналізовано три основні архітектури: згорткові нейронні мережі (CNN), резидуальні мережі (ResNet) та трансформери для зображень (ViT). Основну увагу приділено їхньому впливу на точність, обчислювальну ефективність і здатність до генералізації.

Особливості реалізації моделей, для порівняння обрано такі моделі:

- CNN на базі архітектури VGG16;
- ResNet50 як представник резидуальних нейронних мереж;
- Vision Transformers (ViT), адаптовані для задач класифікації зображень.

Вхідні дані, для навчання використовувався набір даних ChestX-ray14 із розміром зображень  $256 \times 256$  пікселів.

Етапи навчання, моделі навчалися на 80% даних, 10% використовувалися для валідації, а 10% – для тестування.

Для порівняння моделей використовували метрики: точність (Accuracy), чутливість (Sensitivity), специфічність (Specificity) та обчислювальна складність.

Порівняння ефективності моделей наведено у таблиці 3.2.

Таблиця 3.2 – Порівняння ефективності моделей

Архітектура	Точність (%)	Чутливість (%)	Специфічність (%)	Обчислювальна складність (флопси)
CNN (VGG16)	88.5	85.2	91.1	15 GFLOPs
ResNet50	94.2	91.5	96.8	25 GFLOPs
ViT	95.3	92.8	97.4	45 GFLOPs

CNN (VGG16) – CNN добре підходить для базових задач класифікації завдяки своїй здатності виділяти ключові ознаки зображень. Проте її продуктивність обмежена на складних медичних зображеннях із низьким контрастом.

ResNet50 – використання механізму пропуску шарів (skip connections) дозволяє уникнути проблеми зникання градієнтів, забезпечуючи високу точність навіть на складних даних. ResNet50 має кращу здатність до генералізації порівняно з базовими CNN.

Vision Transformers (ViT) – ViT виявляє взаємозв'язки між різними частинами зображення, що дозволяє досягти найвищої точності. Проте ці моделі мають високу обчислювальну складність, що може обмежити їхнє використання на менш потужному обладнанні.

Для задач, де важливі точність і здатність працювати з великими зображеннями (наприклад, МРТ, КТ), ViT є оптимальним вибором. Проте у випадках, де необхідна обчислювальна ефективність, ResNet50 є більш

збалансованим варіантом. CNN залишається хорошим вибором для базових застосувань із менш вимогливими даними.

### 3.3 Вплив розміру та типу зображень на продуктивність моделей

Ефективність нейронних мереж значною мірою залежить від якості та розміру зображень, що використовуються під час навчання та тестування. У цьому розділі аналізується вплив розмірів вхідних даних та їхніх типів на продуктивність моделей класифікації медичних зображень. Результати показують, як різні параметри даних можуть змінювати точність, чутливість і швидкість обробки.

Розмір зображень визначає кількість пікселів, які обробляє модель. Для аналізу були обрані розміри  $32 \times 32$ ,  $128 \times 128$  і  $224 \times 224$  пікселів.

Малі розміри ( $32 \times 32$ ) – зменшення розміру даних значно знижує обчислювальну складність, проте зменшується кількість деталей, що може бути критично важливо для виявлення дрібних патологій, таких як невеликі ураження.

Точність: 86%, Чутливість: 81%, Специфічність: 89%.

Середні розміри ( $128 \times 128$ ) – оптимальний баланс між деталізацією та обчислювальними ресурсами. Цей розмір забезпечує збереження ключових ознак патологій та помірну швидкість обробки.

Точність: 94.2%, Чутливість: 91.5%, Специфічність: 96.8%.

Великі розміри ( $224 \times 224$ ) – збільшення деталізації покращує точність для складних задач, але потребує значно більше ресурсів, що ускладнює навчання.

Точність: 95.8%, Чутливість: 93.4%, Специфічність: 97.1%.

На рисунку 3.1 представлено вплив розміру зображень на продуктивність моделей.




Рисунок 3.1 – Вплив розміру зображень на продуктивність моделей

Типи медичних зображень також мають значний вплив на результати. Були проаналізовані рентгенівські знімки (X-Ray), комп'ютерна томографія (КТ) і магнітно-резонансна томографія (МРТ).

Рентгенівські знімки (X-Ray) – найпоширеніший тип даних. Відносно прості для обробки через їхню низьку складність.

Точність: 94%, Чутливість: 91%, Специфічність: 96%.

КТ-зображення – висока деталізація дозволяє краще розпізнавати складні патології, проте великий обсяг даних ускладнює навчання.

Точність: 96%, Чутливість: 93%, Специфічність: 97%.

МРТ-зображення – складність текстури та деталізація є викликом для моделей. Необхідні більш складні архітектури для обробки. Точність: 93%,

чутливість: 89%, специфічність: 95%.

На рисунку 3.2 порівняно результати для різних типів медичних зображень.




Рисунок 3.2 – Порівняння результатів для різних типів медичних зображень

### 3.4 Оптимізація параметрів для покращення точності

Оптимізація параметрів є важливим етапом покращення точності моделей машинного навчання, зокрема для задач класифікації медичних зображень. Цей процес включає вибір оптимальних гіперпараметрів, корекцію архітектури моделі, використання новітніх методів регуляризації та вдосконалення процесу навчання.

Основні напрями оптимізації:

– вибір оптимальних гіперпараметрів, гіперпараметри, такі як швидкість навчання, розмір пакету даних, кількість епох та кількість нейронів у шарах, мають прямий вплив на точність моделі.

Методи пошуку: сітковий пошук (Grid Search), байєсівська оптимізація (Bayesian Optimization), алгоритм випадкового пошуку (Random Search).

– адаптивна швидкість навчання, використання планувальників швидкості навчання дозволяє автоматично зменшувати цей параметр залежно від зміни функції втрат під час навчання.

Найпоширеніші методи: Step Decay, Exponential Decay, Warm Restarts (Cosine Annealing).

– регуляризація моделі, регуляризація дозволяє уникнути перенавчання, особливо у випадках, коли обсяг навчальних даних є обмеженим.

Dropout: випадкове виключення нейронів у процесі навчання.

L1 та L2 регуляризація: штрафування за занадто великі ваги.

Поліпшення архітектури моделі:

– збільшення глибини моделі глибші моделі, такі як ResNet, дозволяють отримувати кращі результати завдяки можливості вивчати складніші ознаки. Однак це може вимагати додаткових обчислювальних ресурсів;

– додавання нормалізації шарів використання Batch Normalization або Layer Normalization стабілізує навчання, дозволяючи використовувати вищу швидкість навчання;

– модульність моделі розбиття мережі на модулі, такі як головна частина (backbone) для виділення ознак та кінцеві класифікатори (head layers), дозволяє адаптувати модель до різних наборів даних.

Поліпшення якості даних:

– аугментація даних, збільшення кількості навчальних даних за рахунок штучного створення нових зображень: обертання, дзеркальне

відображення, зміна яскравості тощо. Використання бібліотек, таких як Albumentations або TensorFlow ImageDataGenerator;

- зниження шуму в даних, застосування алгоритмів фільтрації та покращення контрасту (CLAHE, Gaussian Blur) для медичних зображень;
- сегментація області інтересу виділення ключових ділянок, наприклад, легенів на рентгенівських знімках, зменшує обсяг непотрібної інформації для моделі.

Використання автоматизованих інструментів для оптимізації параметрів:

- AutoML платформи (наприклад, Google AutoML);
- NAS (Neural Architecture Search) для підбору найкращої архітектури.

Оцінка продуктивності. Після оптимізації параметрів продуктивність моделей оцінюється за допомогою таких метрик, як точність, чутливість, специфічність та F1-міра. Зміна параметрів порівнюється з базовою моделлю.

Результати до та після оптимізації зображені у таблиці 3.4.

Таблиця 3.4 – Результати до та після оптимізації

Метрика	До оптимізації (%)	Після оптимізації (%)
Точність	94.2	96.5
Чутливість	91.5	94.7
Специфічність	96.8	98.3

## 4 ЕТИЧНІ АСПЕКТИ ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В МЕДИЦИНІ

### 4.1 Вимоги до безпеки даних у медичних системах

У медичних системах безпека даних має критичне значення, оскільки вони оперують конфіденційною інформацією пацієнтів. Невиконання вимог безпеки може призвести до витоків даних, втрати довіри пацієнтів і юридичних наслідків. Нижче розглянуті основні аспекти вимог до безпеки в медичних системах.

Захист конфіденційності, конфіденційність є основним принципом у роботі медичних систем:

- шифрування даних, усі дані пацієнтів, як у стані зберігання, так і під час передачі, повинні бути зашифровані;
- аутентифікація користувачів, доступ до даних надається лише авторизованим особам через багатofакторну аутентифікацію;
- доступ за ролями, використання ролей і привілеїв для обмеження доступу до різних частин системи.

Цілісність даних, медичні дані мають бути точними та захищеними від несанкціонованих змін:

- журнали змін, усі дії з даними повинні фіксуватися у журналах для аудиту;
- цифрові підписи, дані пацієнтів підписуються, щоб забезпечити неможливість їх підробки;
- резервне копіювання, регулярне створення резервних копій для запобігання втраті інформації.

Захист від кібератак, медичні системи часто стають ціллю кібератак, таких як ransomware, тому необхідні:

- фаєрволи та антивірусні системи, захист мережевих з'єднань і виявлення шкідливих програм;

- оновлення програмного забезпечення, регулярне встановлення патчів для усунення вразливостей;

- моніторинг загроз, постійний моніторинг активності для виявлення підозрілих дій.

Відповідність законодавству, медичні системи повинні відповідати міжнародним і локальним стандартам:

- GDPR (Загальний регламент захисту даних): У Європі необхідно дотримуватись норм захисту даних пацієнтів;

- HIPAA (Закон про перенесення та підзвітність медичного страхування): У США існують вимоги до конфіденційності та безпеки медичних записів;

- ISO 27001: Стандарти інформаційної безпеки для медичних організацій.

#### 4.2 Етичні і юридичні аспекти використання нейронних мереж у діагностиці

Застосування нейронних мереж у медичній діагностиці відкриває нові можливості для покращення точності, швидкості та доступності медичних послуг. Проте їх використання пов'язане з низкою етичних викликів і юридичних наслідків, що стосуються конфіденційності, справедливості, відповідальності, і довіри до результатів.

Принципи етичного використання і запобігання юридичних наслідків:

- конфіденційність та приватність, захист персональних даних пацієнтів є основним етичним зобов'язанням. Використання нейронних мереж вимагає великих обсягів даних, які повинні бути – анонімізовані перед використанням, захищені відповідно до стандартів GDPR, HIPAA та інших законодавчих норм міжнародного та діючого в країні права;

– справедливість та відсутність упередженості, нейронні мережі можуть відтворювати або підсилювати існуючі соціальні чи етнічні упередження, якщо навчальні дані є нерепрезентативними. Наприклад, якщо модель навчається на даних, де переважають пацієнти однієї етнічної групи, вона може працювати менш ефективно для інших груп;

– інформована згода, пацієнти повинні бути проінформовані про те, як їхні дані використовуються у діагностиці з використанням нейронних мереж, а також надати згоду на обробку цих даних.

Роль відповідальності:

– довірливість до моделей, висока точність нейронних мереж не гарантує відсутності помилок. Лікарі повинні розуміти обмеження моделей і уникати повної автоматизації процесу діагностики;

– відповідальність за помилки, у разі помилкових діагнозів, питання про відповідальність є складним. Чи несе відповідальність розробник нейронної мережі, медичний заклад або лікар, який використовував систему? Вважаємо, так;

Вплив на лікарів та пацієнтів:

– взаємодія лікарів і нейронних мереж, існує ризик того, що лікарі можуть почати сліпо довіряти системам, втрачаючи свої навички критичного мислення. Це створює етичну дилему та юридичні наслідки – як балансувати між автоматизацією і людським контролем?;

– психологічний вплив на пацієнтів, пацієнти можуть мати сумніви щодо діагнозів, які пропонуються штучним інтелектом, через недовіру до технологій або страх перед автоматизованими системами.

Вирішення етичних та юридичних проблем:

– регулювання та стандартизація, необхідно впроваджувати законодавчі, нормативні акти та стандарти для етичного використання нейронних мереж у медицині;

– прозорість алгоритмів, алгоритми нейронних мереж повинні бути пояснювальними, щоб лікарі могли розуміти логіку їх рішень;

– навчання медичних працівників, лікарі повинні отримувати спеціальні знання про роботу з нейронними мережами, їх можливості та обмеження.

## ВИСНОВКИ

Метою цієї роботи є дослідження можливостей штучних нейронних мереж для розпізнавання образів у медичних системах, аналіз їх ефективності та оптимізація параметрів моделей для підвищення точності.

У ході роботи виконано:

- аналіз сучасних архітектур нейронних мереж, таких як CNN, ResNet та Vision Transformers, з оцінкою їх переваг та недоліків у задачах класифікації медичних зображень;

- дослідження впливу різних факторів, включаючи розмір і тип зображень, на продуктивність моделей. Це дозволило визначити оптимальні параметри, зокрема, розмір зображень  $256 \times 256$  пікселів як найбільш ефективний;

- впровадження процедур тестування, валідації та оцінки моделей на реальних медичних наборах даних, що дало змогу досягти високих значень метрик: точність – 94.2%, чутливість – 91.5%, специфічність – 96.8%.

Результати дослідження підтвердили:

- використання штучних нейронних мереж дозволяє суттєво підвищити ефективність автоматизованих систем діагностики;

- важливість оптимізації моделей шляхом аугментації даних, підбору гіперпараметрів та використання сучасних методів регуляризації.

Розроблена система відповідає вимогам технічного завдання, забезпечуючи автоматизоване розпізнавання патологій із високою точністю та мінімізацією помилок. Подальші дослідження можуть бути спрямовані на інтеграцію розроблених моделей у клінічні системи, а також на використання мультимодальних даних (наприклад, КТ і МРТ одночасно) для поліпшення точності діагностики.

**ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Bengio Y., Courville A., Goodfellow I. Deep Learning. MIT Press, 2016. 800 p.
2. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint, 2015. URL: <https://doi.org/10.48550/arXiv.1409.1556> (date of access: 07.12.2024).
3. Tan M., Le Q.V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. Proceedings of the 36th International Conference on Machine Learning (ICML). 2019. URL: <https://doi.org/10.48550/arXiv.1905.11946> (date of access: 07.12.2024).
4. Deep Residual Learning for Image Recognition / K. He et al. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 27–30 June 2016. 2016. URL: <https://doi.org/10.1109/cvpr.2016.90> (date of access: 10.12.2024).
5. Vaswani A., Shazeer N., Parmar N., et al. Attention is All You Need. *Advances in Neural Information Processing Systems*. 2017. URL: <https://doi.org/10.48550/arXiv.1706.03762> (date of access: 07.12.2024).
6. Going deeper with convolutions / C. Szegedy et al. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, 7–12 June 2015. 2015. URL: <https://doi.org/10.1109/cvpr.2015.7298594> (date of access: 10.12.2024).
7. Yang J., Shi R., Ni B. MedMNIST Classification Decathlon: A Lightweight AutoML Benchmark for Medical Image Analysis. *2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI)*, Nice, France, 13–16 April 2021. 2021. URL: <https://doi.org/10.1109/isbi48211.2021.9434062> (date of access: 10.12.2024).
8. Kaggle Datasets. Medical Image Analysis. URL: <https://www.kaggle.com/> (date of access: 10.12.2024).

9. TensorFlow Documentation. URL: <https://www.tensorflow.org/> (date of access: 10.12.2024).
10. PyTorch Documentation. URL: <https://pytorch.org/> (date of access: 10.12.2024).
11. Методичні вказівки щодо підготовки кваліфікаційної роботи магістра спеціальності 122 «Комп'ютерні науки» / Харків: ХНУРЕ, 2023. 55 с.
12. ДСТУ 3008:2015. Державний стандарт України. Інформація та документація. Звіти у сфері науки і техніки. Структура та правила оформлення. Київ: ДП «УкрНДНЦ», 2016. 31 с.
13. Kaggle Competition: RSNA Pneumonia Detection Challenge. URL: <https://www.kaggle.com/c/rsna-pneumonia-detection-challenge> (дата звернення: 12.12.2024).
14. Vision Transformers in Medicine: Applications and Challenges. IEEE Transactions on Medical Imaging, 2021. URL: <https://doi.org/10.1109/TMI.2021.3096319> (date of access: 10.12.2024).
15. ДСТУ 8302:2015. Бібліографічне посилання. Загальні положення та правила складання. Київ: ДП «УкрНДНЦ», 2016. 20 с.
16. NVIDIA Deep Learning GPU Documentation. URL: <https://developer.nvidia.com/deep-learning> (date of access: 10.12.2024).
17. Topol E.J. High-Performance Medicine: The Convergence of Human and Artificial Intelligence. *Nature Medicine*. 2019. URL: <https://doi.org/10.1038/s41591-018-0300-7> (date of access: 10.12.2024).
18. ITK-SNAP Medical Image Segmentation Tool. URL: <http://www.itksnap.org/> (date of access: 19.12.2024).
19. NVIDIA Clara Medical Imaging Platform. – URL: <https://developer.nvidia.com/clara-medical-imaging> (date of access: 20.12.2024).
20. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017. Vol. 60,

Issue 6. P. 84–90. URL: <https://doi.org/10.1145/3065386> (date of access: 20.12.2024).