

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
Кафедра Програмної інженерії

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

другий магістерський
(рівень вищої освіти)

Дослідження методів розпізнавання дерматологічних захворювань на зображеннях за допомогою штучного інтелекту

Виконав:
студент 2 курсу групи ІІЗм-22-2
Гунько Н.А.
(прізвище, ініціали)

Спеціальність 121 – Інженерія програмного забезпечення

Тип програми Освітньо-наукова

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

Допускається до захисту

Зав. Кафедри _____

З.В. Дудар

2024 р.

Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук _____

Кафедра _____ Програмної інженерії _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 121 – Інженерія програмного забезпечення _____
(код і повна назва)

Тип програми _____ освітньо-наукова програма _____

Освітня програма _____ Інженерія програмного забезпечення _____

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

«__» _____ 2024 р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ

студента _____ Гунько Нікіті Андрійовичу _____
(прізвище, ім'я, по-батькові)

1. Тема роботи «Дослідження методів розпізнавання дерматологічних захворювань на зображеннях за допомогою штучного інтелекту»
затверджена наказом університету від «29» березня 2023 р. № 140Ст
2. Термін подання студентом роботи до екзаменаційної комісії «07» червня 2024 р.
3. Вихідні дані до роботи встановлений календарний план роботи, методичні вказівки до оформлення пояснювальної записки, опис нейронних мереж для розпізнавання дерматологічних захворювань на зображеннях, набір даних для тренування та тестування мереж.
4. Перелік питань, що потрібно опрацювати в роботі: аналіз предметної галузі, огляд наявних нейронних мереж для дослідження, обґрунтований вибір нейронних мереж, стратегія проведення дослідження, аналіз порівняльних характеристик, проведення експерименту та аналіз результатів.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Аналіз предметної галузі	29.03.2024	<i>виконано</i>
2	Виявлення проблематики галузі	31.04.2024	<i>виконано</i>
3	Здійснення огляду математичних моделей	03.04.2024	<i>виконано</i>
4	Розробка алгоритму передобробки даних	06.04.2024	<i>виконано</i>
5	Дослідження можливості прискорення	08.04.2024	<i>виконано</i>
6	Побудова плану експерименту	10.04.2024	<i>виконано</i>
7	Імплементация прототипів обраних моделей	12.04.2024	<i>виконано</i>
8	Аналіз результатів експерименту	13.04.2024	<i>виконано</i>
9	Написання пояснювальної записки	18.04.2024	<i>виконано</i>
10	Підготовка доповіді та презентації	24.05.2024	<i>виконано</i>
11	Підготовка роботи для перевірки на антиплагіат та проходження нормоконтролю	27.05.2024	<i>виконано</i>
12	Оцінка роботи рецензентом	02.06.2024	<i>виконано</i>
13	Отримання відзиву від керівника роботи	03.06.2024	<i>виконано</i>
12	Попередній захист кваліфікаційної роботи	04.06.2024	<i>виконано</i>
13	Здача роботи у електронний архів	05.06.2024	<i>виконано</i>
14	Отримання допуску до захисту	06.06.2024	<i>виконано</i>
15	Захист кваліфікаційної роботи	07.06.2024	<i>виконано</i>

Дата видачі завдання _____ 2023 р.

Студент _____
(підпис)

Керівник роботи _____ доц. Вечур О.В. _____
(підпис) (посада, прізвище, ініціали)

РЕФЕРАТ / ABSTRACT

Пояснювальна записка до кваліфікаційної роботи, 69 сторінок, 33 рисунки, 7 таблиць, 5 додатків, 13 джерел.

АНАЛІЗ ПОРІВНЯННЯ, ВИЯВЛЕННЯ ОБ'ЄКТІВ, ДЕРМАТОЛОГІЯ, КОМП'ЮТЕРНИЙ ЗІР, КВАЛІФІКАЦІЙНА РОБОТА, ЛІКУВАННЯ, МАШИННЕ НАВЧАННЯ, МЕДИЦИНА, НЕЙРОМЕРЕЖІ, AI, COMPARATIVE ANALYSIS, COMPUTER VISION, CONTENT GENERATION, DERMATOLOGY, MACHINE LEARNING, MEDICINE, NEURAL NETWORKS, OBJECT DETECTION, PYTHON, QUALIFICATION WORK.

Об'єктом дослідження є виявлення дерматологічних захворювань шляхом аналізу відповідних зображень з використанням різних моделей нейронних мереж, які перед тим були піддані попередньому навчанню на відповідному тренувальному наборі даних. У роботі проведено детальний порівняльний аналіз популярних нейронних мереж з метою визначення їх ефективності в контексті виявлення дерматологічних захворювань.

Основною метою дослідження є навчання вибору найкращих моделей нейронних мереж на основі тренувального набору даних для вирішення завдань розпізнавання дерматологічних захворювань за допомогою зображень людської шкіри. Крім того, мета включає проведення комплексного порівняльного аналізу за допомогою відповідних критеріїв та оцінок з метою визначення найбільш ефективної моделі в контексті дерматологічних захворювань.

Для дослідження спершу було визначено перелік нейронних мереж які є найбільш відповідними для задачі дослідження. Після цього кожну з нейронних мереж було натреновано за допомогою відповідного набору даних з однаковими налаштуваннями параметрів для тренування. Після тренування нейронних мереж кожна з них була перевірена за допомогою тестового набору даних, а також в процесі було використано порівняльні метрики які найбільш розповсюджені та

стандартизовані у сфері машинного навчання. Під час дослідження було використано різні типи архітектури нейронних мереж для того щоб оцінка була найбільш точною та якісною.

Результати дослідження розкривають доцільність використання нейронних мереж в дерматології в цілому, а також показує актуальність сучасних архітектур і моделей у цій сфері. Окрім цього, дослідження визначає найбільш ефективну модель та її архітектуру в аналізі людської шкіри та виявленні дерматологічних захворювань на ній. Результати розкривають суттєве уявлення про можливості нейронних мереж в сфері аналізу шкіри. Дослідження визначає найефективнішу модель нейронної мережі для задачі комп'ютерного зору, який може бути конкурентоспроможним з експертним аналізом медичних робітників. Ця робота представляє елементи наукової новизни, надаючи порівняльний аналіз різних моделей штучного інтелекту проти виявлення дерматологічних захворювань, відносно недослідженої області яка наразі є дуже важливою.

Ключові результати включають детальну оцінку продуктивності нейронних мереж в задачі аналізу зображень людини задля виявлення дерматологічних захворювань. Результати дослідження знайдуть практичне застосування в медицині медіа та онлайн консультаціях з лікарями.

Робота робить внесок у ширшу сферу штучного інтелекту та медицини, пропонуючи рекомендації щодо використання моделей нейронних мереж у задачах медицини. Він закладає основу для майбутніх досліджень щодо покращення можливостей штучного інтелекту в цій галузі.

Економічна та соціально-економічна ефективність роботи полягає в її потенціалі для оптимізації процесу прийому в лікарів та консультації з ними, роблячи великий внесок у розвантаженні лікарень та звільненні графіку лікарів. А також у економії часу як лікарів так і пацієнтів, задля полегшення визначення діагнозу та діагностики захворювань що суттєво зменшить навантаження на сферу медицини.

Важливість цього дослідження полягає в його комплексній оцінці ролі штучного інтелекту в медицині, сприяючи як академічним дослідженням, так і практичним застосуванням.

Висновки вказують на необхідність та важливість подальших наукових досліджень у даній області, зокрема у вдосконаленні моделей штучного інтелекту для більш точного аналізу дерматологічних захворювань.

AI, COMPARATIVE ANALYSIS, COMPUTER VISION, CONTENT GENERATION, DERMATOLOGY, MACHINE LEARNING, MEDICINE, NEURAL NETWORKS, OBJECT DETECTION, PYTHON, QUALIFICATION WORK.

The object of the research is the detection of dermatological diseases through the analysis of relevant images using various neural network models that were previously trained on the corresponding training dataset. The study includes a detailed comparative analysis of popular neural networks to determine their effectiveness in the context of dermatological disease detection.

The main goal of the research is to train a selection of neural network models based on a training dataset for the task of recognizing dermatological diseases through images of human skin. Additionally, the objective involves conducting a comprehensive comparative analysis using appropriate criteria and evaluations to identify the most effective model in the context of dermatological diseases.

For the research, a list of neural networks most suitable for the investigation task was initially identified. Each of these neural networks was then trained using a relevant dataset with consistent training parameters. After training, each network was evaluated using a test dataset, employing comparative metrics widely standardized in the field of machine learning. Various neural network architectures were utilized during the investigation to ensure the assessment was accurate and qualitative.

The results of the research highlight the viability of using neural networks in dermatology overall and demonstrate the relevance of contemporary architectures and models in this field. Furthermore, the study identifies the most effective model and its

architecture for analyzing human skin and detecting dermatological diseases. The findings provide significant insights into the capabilities of neural networks in skin analysis, contributing to an area that is currently of great importance.

Key findings include a detailed performance evaluation of neural networks in the task of analyzing human images for dermatological disease detection. The research results will find practical applications in medical media and online consultations with doctors.

The work contributes to the broader fields of artificial intelligence and medicine by offering recommendations for the use of neural network models in medical tasks. It lays the groundwork for future research aimed at improving the capabilities of artificial intelligence in this domain.

The economic and socio-economic efficiency of the work lies in its potential to optimize the process of doctor consultations, making a significant contribution to relieving hospitals and freeing up doctors' schedules. Additionally, it saves time for both doctors and patients, facilitating the diagnosis and detection of diseases, thus significantly reducing the burden on the healthcare sector.

The significance of this research lies in its comprehensive assessment of the role of artificial intelligence in medicine, contributing to both academic research and practical applications. The conclusions underscore the necessity and importance of further scientific research in this area, particularly in refining artificial intelligence models for more accurate dermatological analysis.

Я, Гунько Нікіта Андрійович, студент групи ПЗМ-22-2 здобувач вищої освіти на другому (магістерському) рівні кафедра «Програмна інженерія», заявляю: моя кваліфікаційна робота на тему «Дослідження методів розпізнавання дерматологічних захворювань на зображеннях за допомогою штучного інтелекту», що буде представлена до ЕК для публічного захисту, виконана самостійно, в ній не

містяться елементи плагіату і вона може бути опублікована в електронному архіві відкритого доступу EIArKhNURE. Всі запозичення з друкованих та електронних джерел мають відповідні посилання.

Я ознайомлений (а) з діючим положенням «Про протидію академічному плагіату в ХНУРЕ», згідно з яким виявлення плагіату є підставою для відмови в допуску кваліфікаційної роботи до захисту та застосування дисциплінарних заходів.

ЗМІСТ

Вступ	10
1 Аналіз предметної галузі	12
1.1 Аналіз предметної галузі дослідження	12
1.2 Аналіз аналогів та актуалізація рішень	18
1.3 Актуальність та мета дослідження	20
1.4 Постановка задачі	21
2 Аналіз методів дослідження	22
2.1 Огляд та вибір набору даних	22
2.2 Огляд обраних моделей для дослідження	24
2.3 Аналіз обраних моделей для дослідження	27
3 Аналіз результатів	32
4 Програмна реалізація	43
Висновки	45
Перелік джерел посилання	46
Додаток А Перелік джерел посилання за науковими напрямками керівника та науковців кафедри програмної інженерії	48
Додаток Б Звіт результатів перевірки роботи на унікальність тексту	49
Додаток В Наукові публікації	50
Додаток Г Презентаційні слайди для захисту кваліфікаційної роботи	59
Додаток Д Експертний висновок результатів перевірки кваліфікаційної роботи на відповідність оформлення вимогам ДСТУ 3008:2015	67

ВСТУП

У наш час, коли штучний інтелект (ШІ) стає невід'ємною складовою різних галузей промисловості, медицина визнана однією з найбільш перспективних сфер його застосування. Вирішення важливих проблем та удосконалення процесів у медичній сфері стає реальністю завдяки впровадженню технологій штучного інтелекту.

Одним із важливих напрямків є постійне удосконалення методів діагностики шкірних захворювань за допомогою алгоритмів ШІ. Автоматизована система, що базується на ШІ, може ефективно аналізувати зображення дерматологічних захворювань і точно визначати патології, забезпечуючи швидку та точну діагностику. Зокрема, алгоритми машинного навчання можуть впізнавати характеристики різних уражень шкіри та надавати інформацію, яка є важливою для лікарів у процесі прийняття вирішальних рішень щодо лікування.

Іншим важливим кроком є розробка систем аналізу медичних зображень, що дозволяють ідентифікувати зміни на клітинному та тканинному рівнях. Це відкриває нові можливості для виявлення ранніх стадій захворювань та запобігання їхньому прогресуванню.

Звісно, такий підхід породжує свої виклики, включаючи необхідність надійного навчання алгоритмів на великій кількості різноманітних клінічних випадків та постійного оновлення бази даних для забезпечення високої точності розпізнавання.

Усі ці зусилля підкреслюють, що використання штучного інтелекту в дерматології може суттєво полегшити ранню діагностику та лікування шкірних захворювань, сприяючи підвищенню ефективності та результативності медичного втручання в цій важливій галузі.

Актуальність цього дослідження полягає у тому що наразі ця ніша не має достатню кількість наявних досліджень та ресурсів які дозволяють пропрацювати уніфікований підхід та розробити якісні та ефективні алгоритми. Окрім цього наразі навантаження на медичний сектор є надзвичайно великим і потребує змін,

впровадження даної технології позитивно вплине на тривалість роботи з кожним пацієнтом та допоможе швидше і якісніше визначати та лікувати захворювання навіть на ранніх стадіях. Також це дозволяє реалізувати онлайн-консультації з дерматологами та іншими медичними спеціалістами, замість того щоб їхати до лікарні та стояти в черзі. В цьому дослідженні розглянуто здатність і якість ШІ конкурувати з людиною, а також визначення найбільш ефективного та конкурентоспроможної моделі.

Основна мета цього дослідження полягає в ретельному дослідженні та навчанні різних нейронних мереж за допомогою призначеного навчального набору даних. Цілі включають проведення порівняльного аналізу цих мереж на основі основних якісних метрик, таких як average precision, recall, FPS та інших метрик які загально визначені в machine learning. Такий підхід забезпечує комплексну оцінку кожної з моделей для кращого розуміння доцільності її використання в подібних задачах.

Новизна цього дослідження полягає в його порівняльному аналізі багатьох нейронних мереж і подальшому визначенні найбільш ефективної моделі за допомогою багатокритеріального аналізу. Це дослідження робить внесок у цю сферу, надаючи розуміння залежності архітектури і моделі від якості розпізнавання захворювань.. Його практичне значення підкреслюється його застосовністю в галузі медицини, відкриваючи нові можливості до підходу в лікуванні і проведення діагностики захворювань.

Ця робота базується на глибокому аналізі поточних наукових праць, що включає в себе дослідження архітектури нейронних мереж, алгоритмів computer vision та діагностики дерматологічних захворювань.

Таким чином, це дослідження має на меті забезпечити всебічну оцінку можливостей ШІ в аналізі зображень з метою діагностики та подальшої профілактики захворювань шкіри.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ

1.1 Аналіз предметної галузі дослідження

Стрімкий розвиток в світі ШІ надає змогу значного поліпшення інструментів ПЗ в області медицини. Це відкрило можливості для використання штучного інтелекту в різних аспектах, починаючи від удосконалення процесів діагностики та лікування, закінчуючи розробкою нових методів дослідження в медицині.

Варто відмітити що в області медицини активно розвиваються дерматологічні дослідження та аналіз зображень за допомогою нейронних мереж. Наразі вже існує декілька рішень які мають використання і на практиці для автоматизації цього процесу. Зважаючи на проаналізовані чисельні дослідження можна відмітити що шкіра для кожної людини є унікальною, так само унікальний вигляд мають захворювання на цій шкірі, що значно ускладнює задачу аналізу дерматологічних захворювань. Також варто відмітити що велика кількість захворювань можуть з'являтися на різних ділянках тіла, тож зображення від пацієнтів можуть бути найрізноманітніші. Цей фактор теж доволі сильно підвищує складність задачі.

Окрім цього для зберігання високої точності в розпізнаванні та швидкості діагностики система потребує регулярного навчання на різноманітних клінічних випадках, також база даних з захворюваннями повинна оновлюватись досить часто. Все це може призвести до перетренування нейронної мережі та збільшенню ризиків некоректного аналізу захворювань. Для такої задачі потрібно визначити найкращу модель та її архітектуру яка буде стійка до перетренування і швидкої зміни набору даних.

Таким чином в ході дослідження розглянуто абсолютно різні за архітектурою види нейронних мереж, а саме:

- convolutional neural networks[3];
- transfer learning models;

- object detection models.

Така вибірка архітектур зумовлена тим що є різні архітектури підходять для вирішення різних завдань у дерматології. Наприклад, виявлення об'єктів може бути важливим для локалізації уражень, тоді як передавання навчання може бути корисним при використанні знань які були набуті на інших завданнях. Також різні моделі показують різні результати ефективності на обмеженій кількості дерматологічних зображень, Враховуючи цей фактор можна визначити яка з архітектур зможе видати найкращі результати при обмеженій кількості даних.

Convolutional neural networks. Convolutional neural network може мати сотні шарів, кожен з яких навчається виявляти різні особливості зображення. Фільтри застосовуються до кожного тренувального зображення з різною роздільною здатністю, а вихідні дані кожного згорнутого зображення використовуються як вхідні дані для наступного шару. Фільтри можуть починатися з дуже простих функцій, таких як яскравість і межі і ускладнюються до функцій які однозначно визначають об'єкт. Загальна структура згорточної нейронної мережі наведена на рисунку 1.1.

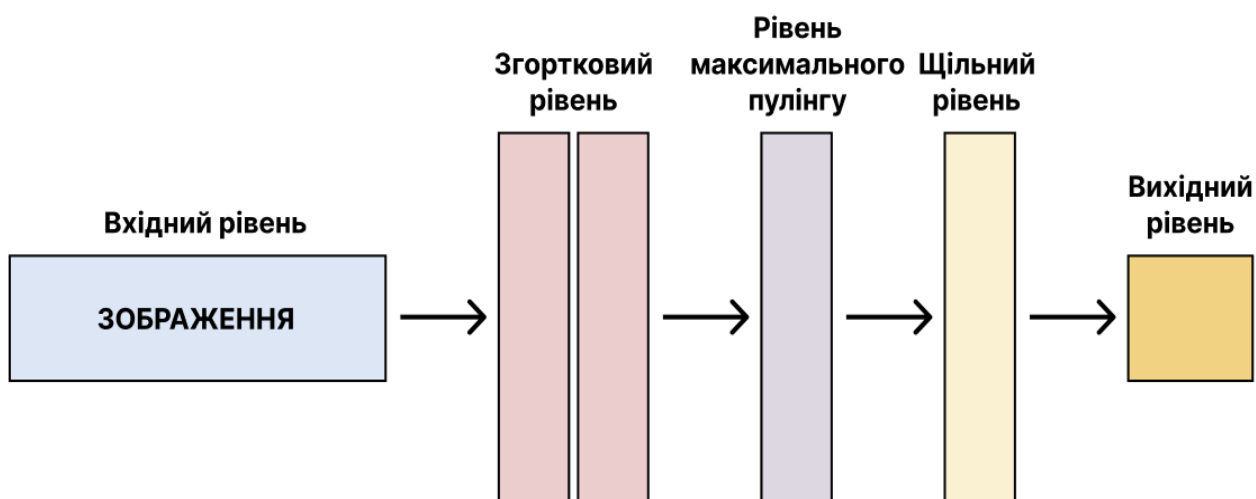


Рисунок 1.1 – Загальна структура згорточної нейронної мережі (за даними [3])

Ці рівні виконують операції, спрямовані на модифікацію даних з метою вивчення їхніх особливостей. Три основні етапи включають в себе згортку, активацію або функцію ReLU та об'єднання.

Процес згортки вводить вхідні зображення через набір згорткових фільтрів, кожен з яких виконує активацію конкретних функцій зображення.

Активація або функція ReLU прискорює та ефективніше навчається, перетворюючи від'ємні значення на нуль і зберігаючи додатні значення. Цей етап часто називається активацією, оскільки лише активовані функції переходять на наступний рівень.

Об'єднання спрощує вихід, проводячи нелінійне зменшення дискретизації та зменшуючи кількість параметрів, які мережа повинна вивчати.

Ці операції повторюються на десятках або сотнях шарів, при цьому кожен шар навчається визначати різні функції для ефективного аналізу даних.

CNN[3] мають ряд переваг та недоліків які мають свій вплив на результати дослідження. Серед переваг можна відмітити здатність автоматично виділяти важливі ознаки на зображеннях, таких як ураження шкіри. Механізм згортки надає змогу нейронним мережам виявляти ієрархічні особливості, забезпечуючи ефективний аналіз.

Ще однією перевагою є здатність пристосовуватися до широкого спектру зображень і здатність генералізувати дані. Це надає більшу ефективність при роботі з абсолютно різними та різноманітними клінічними випадками та різними типами дерматологічних захворювань.

Серед недоліків варто відмітити потребу у великій кількості даних для ефективного навчання. Брак адекватних медичних даних може призвести до погіршення результатів та зменшення точності моделі. Окрім цього важливим аспектом є важкість інтерпретації рішень які обирає CNN. CNN є вразливим до артефактів та виняткових ситуацій, що може вплинути на результати.

Transfer learning models. Transfer learning є важливим методом машинного навчання, який використовує раніше навчену модель для вирішення нових задач. В контексті дерматологічних досліджень та аналізу зображень шкіри, цей підхід

може виявитися особливо ефективним, особливо коли доступ до обширних наборів даних є важкодоступним. Загальна структура transfer learning моделей зображена на рисунку 1.2.

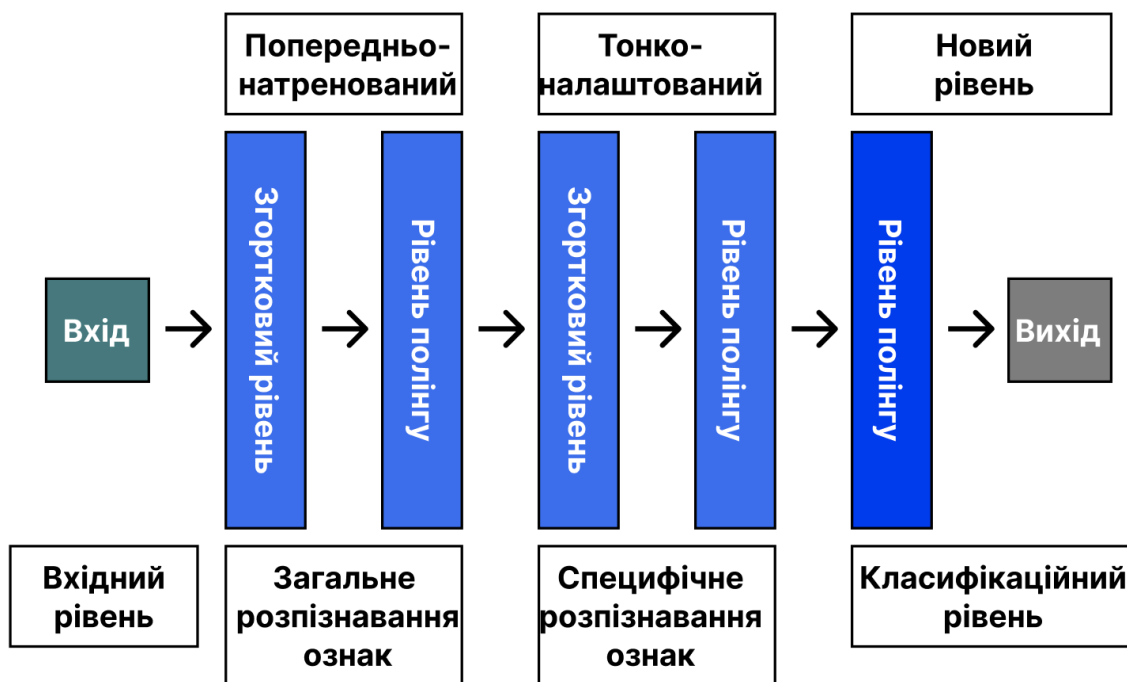


Рисунок 1.2 – Загальна структура transfer learning (за даними [3])

Структура transfer learning включає два ключових етапи. По-перше, модель навчається на великому наборі даних для загальної задачі, наприклад, класифікації зображень. Цей етап дозволяє моделі вивчити загальні особливості та характеристики. Наступним етапом є навчання адаптивної моделі на конкретному наборі даних для вирішення конкретної задачі, наприклад, класифікації дерматологічних захворювань. Рівень полігону в цій схемі це рівень який об'єднує виходи з попереднього шару зменшуючи розмірність даних для зниження обчислювальної вартості.

Переваги використання transfer learning у сфері дерматологічних захворювань та computer vision включають зменшення необхідності у великій кількості даних для ефективного навчання. Це особливо актуально для випадків, коли отримання обширних наборів клінічних даних є важливою трудношстю. Крім того, transfer learning може покращити точність класифікації, дозволяючи адаптивній моделі краще пристосуватися до конкретної задачі.

З усім тим, існують певні виклики. Спростить вибір початкової моделі, яка повинна бути добре підібрана для конкретної задачі. Крім того, адаптація

адаптивної моделі може вимагати додаткового навчання для досягнення оптимальної точності.

Прикладами успішного використання transfer learning є класифікація дерматологічних захворювань, виявлення ракових уражень шкіри та аналіз текстур шкіри. Цей метод виявляється потужним інструментом у сфері дерматології та комп'ютерного зору, сприяючи покращенню точності та ефективності класифікації захворювань шкіри.

Object detection models. Об'єктні детектори представляють собою категорію моделей машинного навчання, які спроможні виявляти та розпізнавати об'єкти на зображеннях чи відео. Вони можуть бути застосовані в різних сферах, включаючи розпізнавання дерматологічних захворювань.

Робочий принцип об'єктних детекторів полягає в пошуку характерних ознак, що вказують на певний об'єкт. Наприклад, детектор, призначений для виявлення ракових уражень шкіри, може враховувати такі ознаки, як нерівна поверхня, зміна кольору та розміру.

Ці моделі можуть використовуватися в дерматології для вирішення таких завдань, як:

- класифікація дерматологічних захворювань: об'єктні детектори дозволяють виявляти різні типи дерматологічних захворювань, таких як псоріаз, екзема та рак шкіри;
- детектування ракових уражень шкіри: ці моделі можуть допомагати виявляти ракові ураження на ранніх стадіях, коли лікування найефективніше;
- аналіз текстур шкіри: вони дозволяють проводити аналіз текстур для виявлення ознак захворювань.

Об'єктні детектори мають свої переваги в дерматології. Вони дозволяють швидко і точно виявляти та класифікувати захворювання шкіри. Також вони є корисним інструментом для ранньої діагностики ракових уражень шкіри.

Проте існують недоліки у використанні об'єктних детекторів. Вони можуть бути менш точними, якщо не навчені на великому обсязі даних. Також вони можуть не впоратися з виявленням нестандартних форм або розмірів дерматологічних захворювань.

Зважаючи на значну кількість альтернативних видів моделей можна припустити що в галузі дерматологічних захворювань може бути фаворит, тому метою цього дослідження є визначення найбільш ефективної моделі та загальної архітектури яка зможе демонструвати точні результати на даних різної якості.

Наукове дослідження передбачає аналіз кожної з нейронних мереж які перед цим будуть натреновані однаковим способом з використанням одного набору даних та ідентичні параметри для тренування. Після тренування аналіз та тестування буде проведено на тестовому датасеті, серед метрик які будуть протестовані є average precision, recall, accuracy, FPS, вартість обчислень і тд.

Мета полягає в тому, щоб визначити найефективнішу нейронну модель, для подальшого використання в медицині.

Дослідження включає як теоретичні дослідження, включаючи алгоритмічні основи та стратегії навчання моделей, так і експериментальні дослідження, які включають фактичне навчання нейронних мереж та аналіз їх результатів. Цей комплексний підхід забезпечує надійне розуміння можливостей різних моделей в задачі аналізу дерматологічних захворювань.

Дослідження включає вивчення технології, яка використовується для тренування нейронної мережі, етапи розробки моделей штучного інтелекту та, при можливості, подання опису розробленої системи програмного забезпечення.

Результати цього дослідження можуть бути використані в сфері медицини і надають важливу інформацію для подальшого розвитку напрямку аналізу дерматологічних захворювань за допомогою ШІ.

1.2 Аналіз аналогів та актуалізація рішень

На сьогоднішній день існує значна кількість інноваційних рішень у сфері дерматології, які використовують штучний інтелект для поліпшення діагностики та моніторингу дерматологічних захворювань. Цей розвиток є відображенням стрімкого зростання інтересу до застосування сучасних технологій у медичній сфері.

Один із визначених аналогів - DermEngine, відзначається можливістю аналізу різноманітних дерматологічних станів за допомогою штучного інтелекту. Він надає лікарям інструменти для точної класифікації захворювань і покращення процесу діагностики.

Ще однією цікавою платформою є SkinVision, мобільний додаток, який дозволяє користувачам завантажувати зображення шкіри та отримувати автоматизовану оцінку ризику захворювання на основі алгоритмів машинного навчання.

Компанія MetaOptima також входить до числа провідних у цій галузі, пропонуючи технології для дерматоскопії та моніторингу шкіри. Вони використовують нейронні мережі для аналізу зображень, щоб надавати лікарям та пацієнтам інструменти для більш детального вивчення стану шкіри та ранньої діагностики.

Ці рішення є лише кількома прикладами зростаючої кількості інструментів, що використовують штучний інтелект у сфері дерматології. Такий розмаїття аналогів свідчить про важливість цього напряму розвитку та його потенційний великий внесок у діагностичні можливості та ефективність медичного обслуговування.

Обмеження в аналізі дерматологічних захворювань за допомогою штучного інтелекту включають технічні складнощі у розпізнаванні різних стадій та варіантів захворювань, відсутність стандартизованих даних та протоколів у галузі дерматології, а також необхідність інтеграції результатів моделей в роботу лікарів та медичних спеціалістів.

Обмеження в аналізі дерматологічних захворювань за допомогою штучного інтелекту включають технічні складнощі у розпізнаванні різних стадій та

варіантів захворювань, відсутність стандартизованих даних та протоколів у галузі дерматології, а також необхідність інтеграції результатів моделей в роботу лікарів та медичних спеціалістів (див. табл. 1.1).

Таблиця 1.1 – Порівняльний аналіз існуючих аналогів

	DermEngine	SkinVision	MoleScope
Опис	Онлайн-платформа для аналізу зображень шкіри	Мобільний додаток, аналізуючий фото шкіри і виявляє ознаки раку шкіри	Онлайн-платформа для діагностики патологій шкіри
Переваги	Висока точність аналізу, інтеграція з іншими медичними системами	Зручний доступ до оцінки ризику захворювань, можливість відстеження змін в часі, швидкі результати	Висока точність діагностики, автоматичне виявлення та аналіз патологій без значного втручання користувача
Недоліки	Дуже висока вартість впровадження, недоступне для звичайних користувачів, лише для клінік, великий час аналізу	Висока вартість для невеликих практик, має проблеми з низько якісними зображеннями та захворюваннями на різних ділянках шкіри	Обмежена в діагностиці нестандартних дерматологічних захворювань, складна у використанні користувачами які не обізнані в цій темі
Технологія III	CNN, Object detection	Transfer learning	CNN

Таким чином, можна побачити що аналоги використовують абсолютно різні моделі та підходи до задачі аналізу захворювань шкіри. І кожен з них має свої переваги та недоліки, що робить це дослідження ще більш актуальним задля визначення уніфікованого підходу.

1.3 Актуальність та мета дослідження

Дослідження є актуальним та значущим в контексті сучасних викликів у галузі медицини та технологій штучного інтелекту (ШІ). Застосування ШІ у сфері дерматології є важливим напрямком, оскільки воно може суттєво покращити ранню діагностику та лікування шкірних захворювань.

Актуальність полягає у тому, що, завдяки використанню алгоритмів машинного навчання та аналізу зображень, можливо автоматизувати процес діагностики шкірних захворювань, зменшуючи навантаження на медичний персонал та прискорюючи прийняття вирішальних рішень. Розробка ефективних та точних алгоритмів для розпізнавання дерматологічних захворювань може виявитись корисною для розширення можливостей медичних установ та поліпшення якості надання медичних послуг.

Мета дослідження полягає у проведенні ретельного аналізу та порівняльного огляду різних нейронних мереж, зокрема, Convolutional Neural Networks (CNN)[7] та Transfer Learning Models[5], в контексті їхнього застосування до діагностики дерматологічних захворювань. Задачею є визначення найбільш ефективних моделей для цієї конкретної задачі та зрозуміти, як їх можна впроваджувати для досягнення максимальної точності та надійності в реальних умовах.

Дослідження є актуальним оскільки воно може призвести до розробки нових інструментів та методів діагностики шкірних захворювань, що в подальшому сприятиме покращенню медичної практики та забезпечить пацієнтів більш точною та швидкою діагностикою.

1.4 Постановка задачі

Головною метою цього дослідження є розробка, навчання та оцінка моделей для аналізу дерматологічних захворювань на основі зображень шкіри. Алгоритм тренування був реалізований за допомогою мови програмування Python.

Цілі цього дослідження полягають у наступному:

- обрати доцільний набір даних який дозволив би провести якісне тренування моделей;
- обрані моделі натренувати з однаковими параметрами та на однаковому наборі даних, виділивши відповідний час для тренування;
- провести експеримент на тестовому наборі даних та внести результати по кожній з моделей;
- провести експеримент на тестовому наборі даних та внести результати по кожній з моделей;
- обрані моделі натренувати з однаковими параметрами та на однаковому наборі даних, виділивши відповідний час для тренування;
- оцінити продуктивність моделі з точки зору зазначених характеристик.

Набір даних отримано з медичних баз даних який містить 10 різних хвороб та налічує близько 19500 зображень, 15500 з яких було виділено на тренування, а решта для валідаційного датасету. Така кількість зображень пов'язана з великим різноманіттям можливих місць для уражень шкіри які суттєво змінюють вигляд зображень та надають більшу похибку.

Ефективність кожної з моделей буде оцінена за кількома параметрами:

- швидкість;
- точність локалізації;

- повнота алгоритму;
- чутливість.

Сумуючи, це дослідження має на меті зробити внесок в область Object Detection в галузі медицини і дозволить розробити уніфікований підхід до задачі розпізнавання дерматологічних захворювань.

2 АНАЛІЗ МЕТОДІВ ДОСЛІДЖЕННЯ

2.1 Огляд та вибір набору даних

Вибір відповідного набору даних є критичним етапом при розробці моделей штучного інтелекту для дерматології і на пряму впливає на ефективність та точність навчання моделі, отже вимагає уважного розгляду різних аспектів. Серед основних критеріїв які, наведено нижче.

Кількість даних. Достатня кількість зображень для кожного класу дерматологічного захворювання важлива для ефективного навчання моделей.

Різноманітність уражень. Набір даних має містити повний спектр дерматологічних захворювань які будуть репрезентувати класи при навчанні. Дані повинні бути повними та мати включати в себе різні ступені важкості захворювання, а також різні його підвиди.

Якість маркування. Дані повинні бути правильно помічені, не мати неадекватних чи аномальних значень які можуть негативно вплинути на якість роботи моделей та призвести до значного погіршення точності та ефективності нейронних мереж[1].

Різноманіття груп пацієнтів. Дані повинні бути підібрані таким чином щоб включати в себе різні типи шкіри пацієнтів, а саме (расова, вікова група і тд) це може дещо збільшити час тренування та вплинути на точність розпізнавання, проте надасть більш стабільну роботу з різними пацієнтами.

Доступність даних. Наявність легкодоступних та відкритих даних сприяє більшому розвитку досліджень та спільноти і допомагає оцінити та покращити вже існуючі набори даних.

Актуальність даних. Дані повинні відповідати останнім стандартам клінічних норм та відповідати останній наявній інформації щодо захворювань. Це є критичним аспектом для того щоб тренування йшло належним чином і не призвело до колізії класів, через те що деякі захворювання мають доволі схожий вигляд та симптоматику.

Безпека Даних. Збір та використання даних мають відповідати вимогам законодавства, зокрема, забезпечувати захист конфіденційності та особистої інформації. Важливо користуватися датасетами, які не містять матеріалів, що можуть спричинити образу чи вважаються неприйнятними.

Вибір набору даних є одним з критичних аспектів для точності роботи моделі. Врахування цих чинників сприяє створенню набору даних, що ефективно підготувати моделі до реальних умов використання. Важливо враховувати значущість кожного з цих аспектів, оскільки вони взаємопов'язані і впливають на загальну ефективність та точність моделей.

2.2 Огляд обраних моделей для дослідження

Наступний крок це аналіз існуючих моделей які мають різну архітектуру в задачі аналізу дерматологічних захворювань. Обрані моделі відповідають останнім тенденціям в machine learning та мають доволі високі оцінки точності та ефективності в задачі дерматології. Серед них буде розглянуто наступні моделі які відповідають трьом основним архітектурним підходам:

- convolutional neural networks (ResNet-50, VGG19);
- transfer learning models (DenseNet).

Далі буде наведено опис та архітектуру кожної з цих моделей.

ResNet відзначається своєю високою ефективністю в розв'язанні завдань дерматологічної детекції з наступних причин. Однією з головних переваг цієї мережі є її здатність ефективно працювати з глибокими мережами, що є важливим для виявлення складних патернів на зображеннях шкіри. Гнучкість у регулюванні глибини ResNet дозволяє використовувати модель залежно від конкретних вимог задачі та обсягу даних.

Можливість використання попередньо навчених моделей, наприклад на основі ImageNet важлива для задач з обмеженим обсягом даних. Попереднє

навчання на великому та різноманітному наборі даних дозволяє моделі вивчати загальні ознаки які можуть бути корисні для аналізу дерматологічних захворювань. Загальна структура моделі наведена на рисунку 2.1.

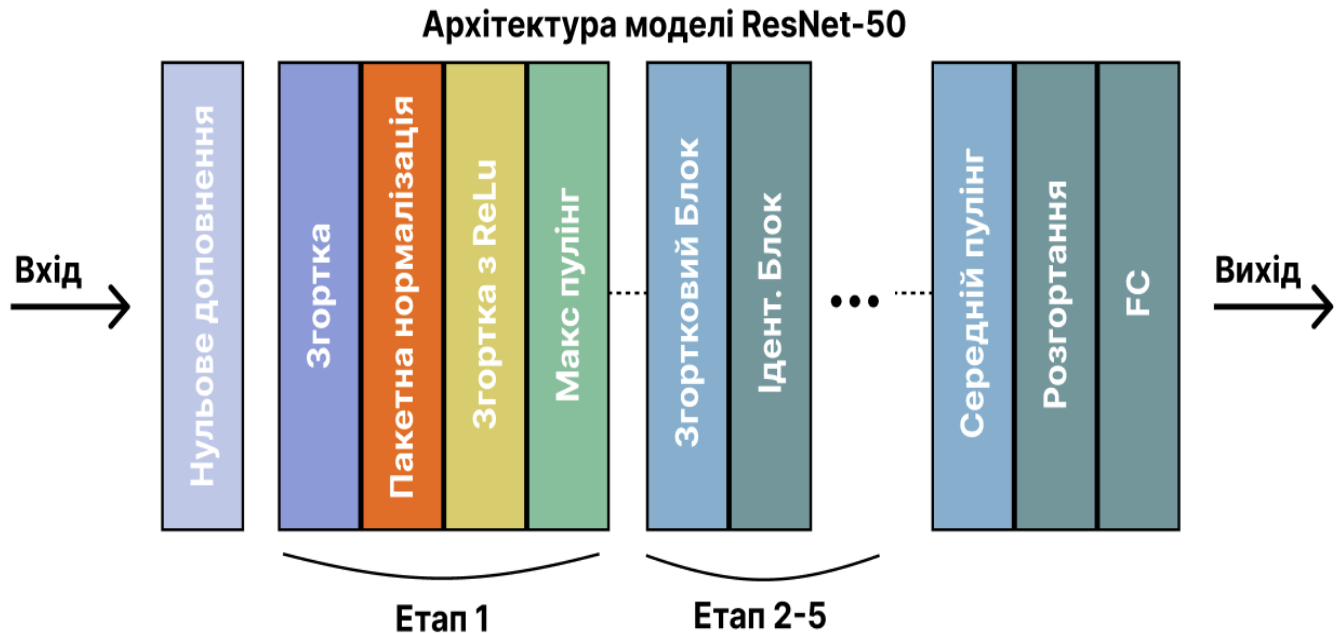


Рисунок 2.1 – Загальна структура ResNet-50 (за даними [3])

Структура ResNet-50 складається з 50 шарів і використовує блоки з залишковим з'єднанням, що дозволяють уникнути проблем втрати градієнту при глибокому навчанні.

Основна структура включає конволюційні шари для виділення характеристик, групи блоків для обробки даних та повнозв'язні шари для рішення завдань, таких як класифікація зображень.

VGG19 є потужним інструментом для задачі аналізу дерматологічних захворювань. Гнучкість у налаштуванні кількості шарів дозволяє легко адаптувати модель до конкретних вимог завдання та розміру набору даних. Окрім цього VGG19 виявляє важливі ознаки на різних рівнях ієрархії, що сприяє отриманню деталізованих результатів у завданнях виявлення захворювань шкіри на зображеннях.

Структура VGG19 наведена на рисунку 2.2.




Рисунок 2.2 – Загальна структура VGG19 (за даними [3])

Структура VGG19 вважається глибокою нейронною мережею яка має 19 шарів. Ці шари включають конволюційні та повнозв'язні шари. Спочатку йдуть конволюційні блоки які повторюються збільшуючи кількість фільтрів на кожному кроці. Після них йдуть повнозв'язані шари серед яких є два шари з функцією ReLU. Завершається модель вихідним повнозв'язаним шаром, який має кількість нейронів, що відповідає кількості класів для класифікації.

DenseNet є високоефективною моделлю яка має тісне з'єднання між шарами мережі, що сприяє більш ефективному використанню функцій та покращеній передачі градієнтів. Модель DenseNet може бути адаптована до різних розмірів наборів даних та вимог завдання. Також висока здатність передачі інформації між

шарами сприяє збереженню та використанню докладних контекстуальних ознак. Структура DenseNet зображена на рисунку 2.3.




Рисунок 2.3 – Загальна структура DenseNet (за даними [2])

Структура DenseNet представляє собою інноваційну модель нейронної мережі, яка характеризується густими зв'язками між шарами. Основна її ідея полягає в тому, що кожен шар отримує вхідні дані не тільки від попереднього шару, але і від усіх попередніх шарів в мережі. Це сприяє ефективній передачі інформації та допомагає уникнути проблем градієнтного зникаючого та спадаючого градієнта в глибоких мережах[10].

Мережа включає щільні блоки, де кожен шар пов'язаний з кожним іншим у тому ж блоку, і блоки переходу, що зменшують розмірність. DenseNet відомий своєю ефективністю при використанні меншої кількості параметрів, що робить його популярним у завданнях обробки зображень, таких як дерматологічні дослідження.

2.3 Аналіз обраних моделей для дослідження

В рамках дослідження було проаналізовано наступні моделі: ResNet-50, VGG19, DenseNet, а також комбінований алгоритм. Далі наведено основні критерії та їх опис для аналізу[6].

В якості критеріїв для цієї задачі було сформовано наступний перелік та пояснення до кожного з критеріїв:

- швидкість роботи (FPS);
- точність локалізації;
- повнота алгоритму;
- чутливість;

FPS – швидкість роботи обробки нейронною мережею зображень, вимірюється кількістю оброблених зображень на секунду. Визначається за формулою наведеною нижче.

$$FPS = \frac{1}{t} \quad (2.1)$$

де t – час обробки 1 кадру.

Точність локалізації (Intersection over union)[12] – окрім правильної класифікації дерматологічного захворювання не менш важливим є правильне визначення місцезнаходження захворювання на зображенні, для цього загальноприйнятим вважається використання метрики intersection over union яка визначається як перекриття між прогнозованою областю об'єкта та актуальною, поділене на їх загальну область.

Основний алгоритм розрахунку наведений на рисунку 2.4.

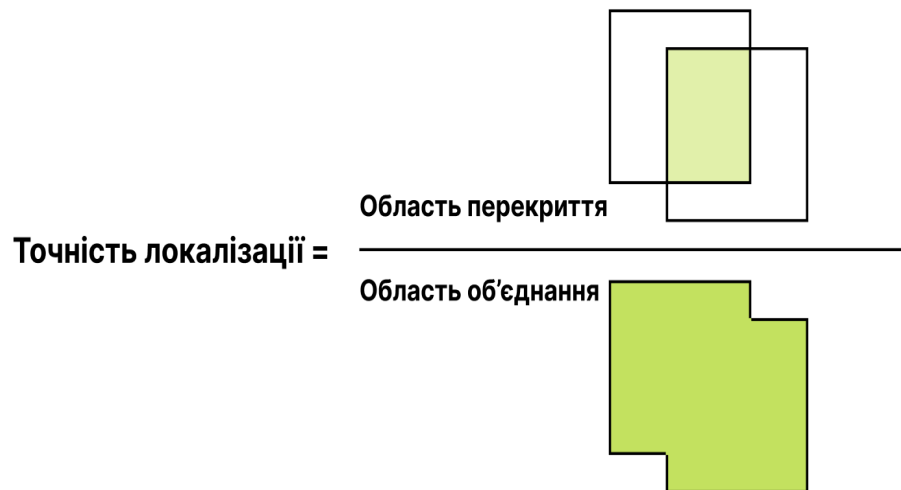


Рисунок 2.4 – Формула точності локалізації (за даними [3])

Повнота алгоритму (Average precision)[12] - ця метрика визначає точність і повноту алгоритму при різних порогових значеннях та обчислюється за допомогою кривої Precision/Recall яка показує динаміку змінення точності та повноти при зміні порогового значення. Формула precision наведена нижче.

$$Precision = \frac{TP}{TP+FP} \quad (2.2)$$

Чутливість (Recall) - метрика, яка вимірює яку частину позитивних прикладів модель змогла виявити, ця метрика також є однією з ключових в області медичних досліджень тому є обов'язковою для цієї теми. Визначається за формулою наведеною нижче.

$$Recall = \frac{TP}{TP+FN} \quad (2.3)$$

Далі наведено тип шкали для кожного з критеріїв:

Швидкість роботи є шкалою інтервалів і має числове значення. Вимірюється в кадрах на секунду, чим більше значення тим швидше працює алгоритм.

Точність локалізації це теж шкала інтервалів і має числове значення та конвертується у відсотки. Вищі значення зумовлюють вищу точність локалізації.

Повнота алгоритму це шкала інтервалів тож значення так само є числовим. Біль високе значення показує більшу повноту алгоритму.

Чутливість відображена шкалою інтервалів, значення від 0 до 1. Чим вище значення тим ефективніше працює мережа.

Далі створена шкала оцінювання для кожного з критеріїв, вона виглядає наступним чином.

а) швидкість роботи:

- 1) 100+: 11 бал;
- 2) 90-99: 2 бали;
- 3) 80-89: 3 бали;
- 4) 70-79: 4 бали;
- 5) 60-69: 5 балів;
- 6) 50-59: 6 балів;
- 7) 40-49: 7 балів;
- 8) 30-39: 8 балів;
- 9) 20-29: 9 балів;
- 10) менше 20: 10 балів;

б) точність (Accuracy):

- 1) 0.9-1.0: 10 балів;
- 2) 0.8-0.89: 9 балів;
- 3) 0.7-0.79: 8 балів;
- 4) 0.6-0.69: 7 балів;
- 5) 0.5-0.59: 6 балів;
- 6) 0.4-0.49: 5 балів;
- 7) 0.3-0.39: 4 бали;
- 8) 0.2-0.29: 3 бали;
- 9) 0.1-0.19: 2 бали;
- 10) менше 0.1: 1 бал;

в) чутливість (Precision):

- 1) 0.9-1.0: 10 балів;
- 2) 0.8-0.89: 9 балів;
- 3) 0.7-0.79: 8 балів;

- 4) 0.6-0.69: 7 балів;
- 5) 0.5-0.59: 6 балів;
- 6) 0.4-0.49: 5 балів;
- 7) 0.3-0.39: 4 бали;
- 8) 0.2-0.29: 3 бали;
- 9) 0.1-0.19: 2 бали;
- 10) менше 0.1: 1 бал;

г) повнота алгоритму (Recall):

- 1) 0.9-1.0: 10 балів;
- 2) 0.8-0.89: 9 балів;
- 3) 0.7-0.79: 8 балів;
- 4) 0.6-0.69: 7 балів;
- 5) 0.5-0.59: 6 балів;
- 6) 0.4-0.49: 5 балів;
- 7) 0.3-0.39: 4 бали;
- 8) 0.2-0.29: 3 бали;
- 9) 0.1-0.19: 2 бали;
- 10) менше 0.1: 1 бал.

Після цього було проведено експеримент над 5ма моделями нейронних мереж, серед яких ResNet-50, DenseNet, VGG19, Faster-R-CNN, і YOLOv4[8]. Моделі тренувались на більш розширеній вибірці які становили 23 класи хвороб. Моделі тренувались 50 епох та загальна кількість зображень набору даних становила близько 19ти тисяч. За результатами експерименту було виявлено 3 моделі-лідери, серед яких ResNet-50, DenseNet та VGG19. Далі проведено другий експеримент з меншою кількістю класів і тільки з моделями-лідерами, це зроблене для того щоб підвищити точність розпізнавання моделей. Тренування проводилось використовуючи набір даних який містить 10000 зображень і 10 класів різних дерматологічних хвороб, а також для валідації було використано набір даних який містить більше 1600 зображень.

Серед доступних класів хвороб було взято наступні:

- acne and rosacea - акне і розацеа;
- actinic keratosis basal cell carcinoma and other malignant lesions - актинічна кератозна базальноклітинна карцинома та інші злоякісні ураження;
- atopic dermatitis - атопічний дерматит;
- bullous disease - бульозний епідермоліз;
- cellulitis impetigo and other bacterial infections - целюліт, імпетіго та інші бактеріальні інфекції;
- eczema - екзема;
- exanthema and drug eruptions - екзантема і алергічні висипання;
- hair loss, alopecia and other hair diseases - втрата волосся, алопеція та інші захворювання волосся;
- herpes HPV and other STDs - герпес, ВПЛ та інші статеві-передавані інфекції;
- light diseases and disorders of pigmentation - фотодерматоз та розлади пігментації.

Детальні результати експерименту наведені в опублікованій науковій статті [11].

3 АНАЛІЗ РЕЗУЛЬТАТІВ

Нейронні моделі були натреновані при однакових умовах використовуючи один і той самий набір даних і одні й ті самі параметри, пройшовши 50 епох тренування. В таблиці 3.1 наведено результати вимірів.

Таблиця 3.1 – Виміри експерименту

Нейронна мережа	Швидкість(мс)	Повнота алгоритму	Чутливість	Точність локалізації
ResNet-50	63.2	0.76	0.80	0.78
VGG19	39.7	0.51	0.44	0.43
DenseNet	42.0	0.67	0.71	0.73
Комбінований алгоритм	144.9	0.74	0.77	0.82

Далі наведено графіки по кожній з нейронних моделей починаючи з ResNet (див. рис. 3.1).

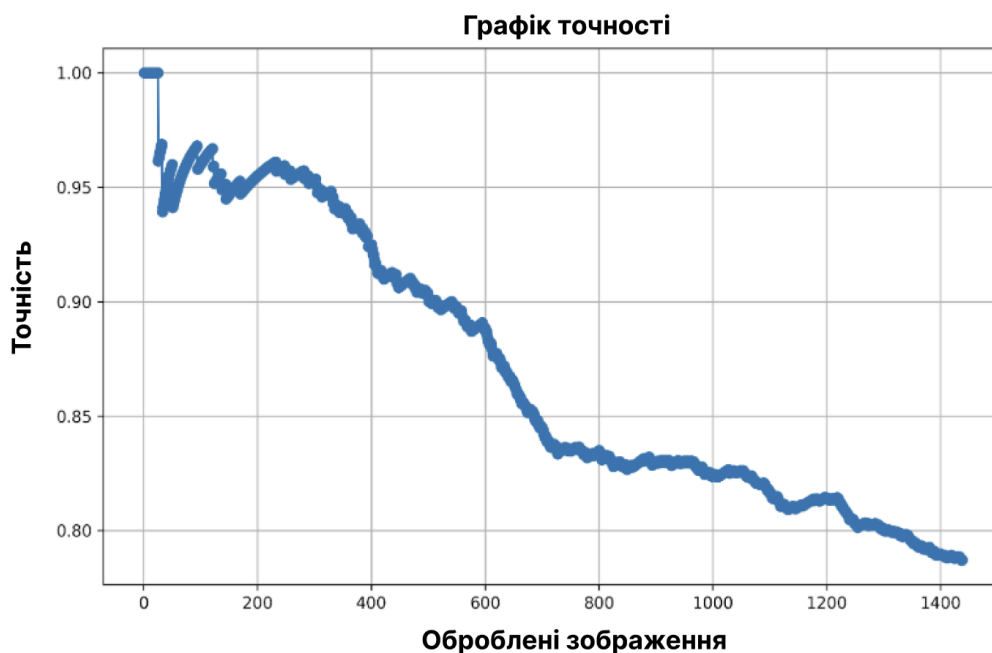


Рисунок 3.1 – Точність локалізації ResNet-50

З графіку видно що Точність локалізації ResNet-50 дорівнює 0.78 на тестовому наборі даних. На рисунку 3.2 зображено чутливість по кожній з хвороб для ResNet-50.

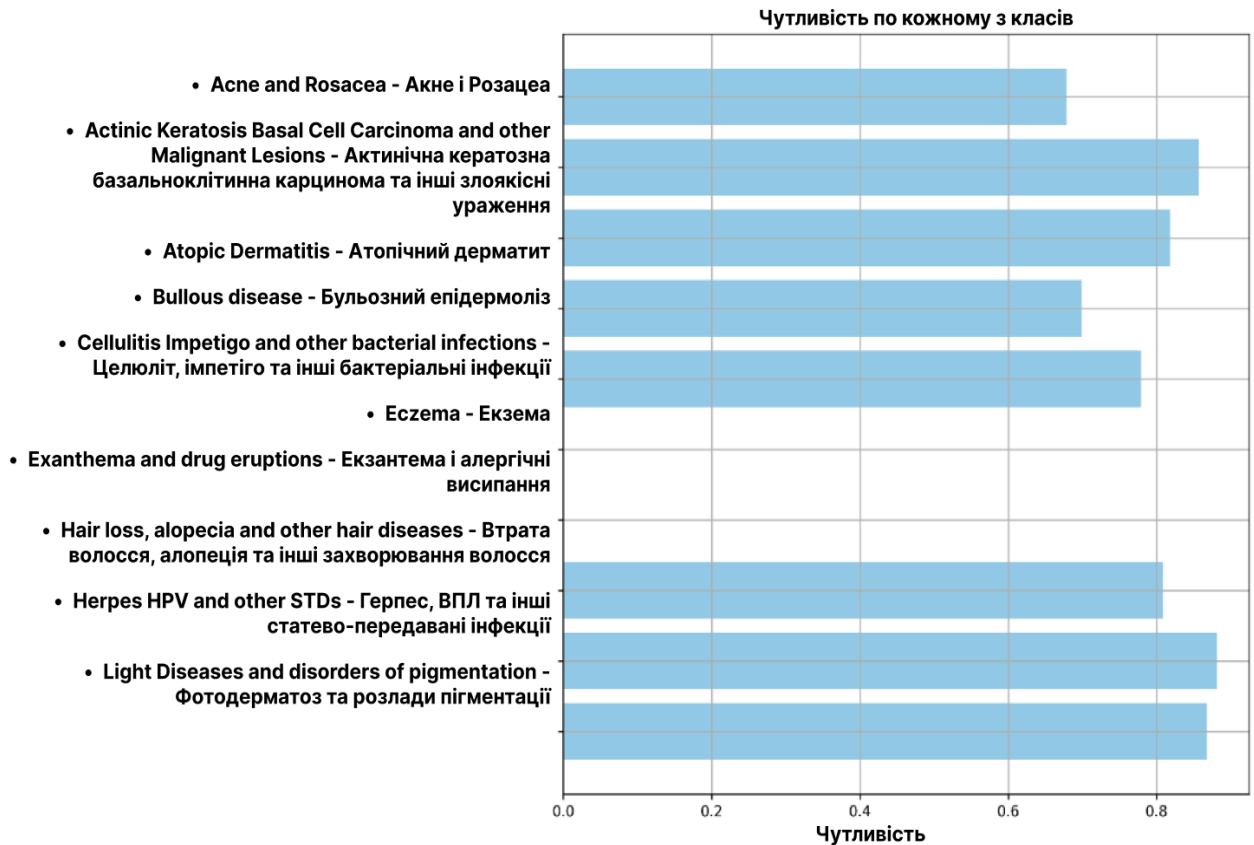


Рисунок 3.2 – Чутливість ResNet-50 (рисунок створено самостійно)

Середня чутливість дорівнює 0.80.

На рисунку 3.3 зображено повноту алгоритму по кожній з хвороб для ResNet-50.

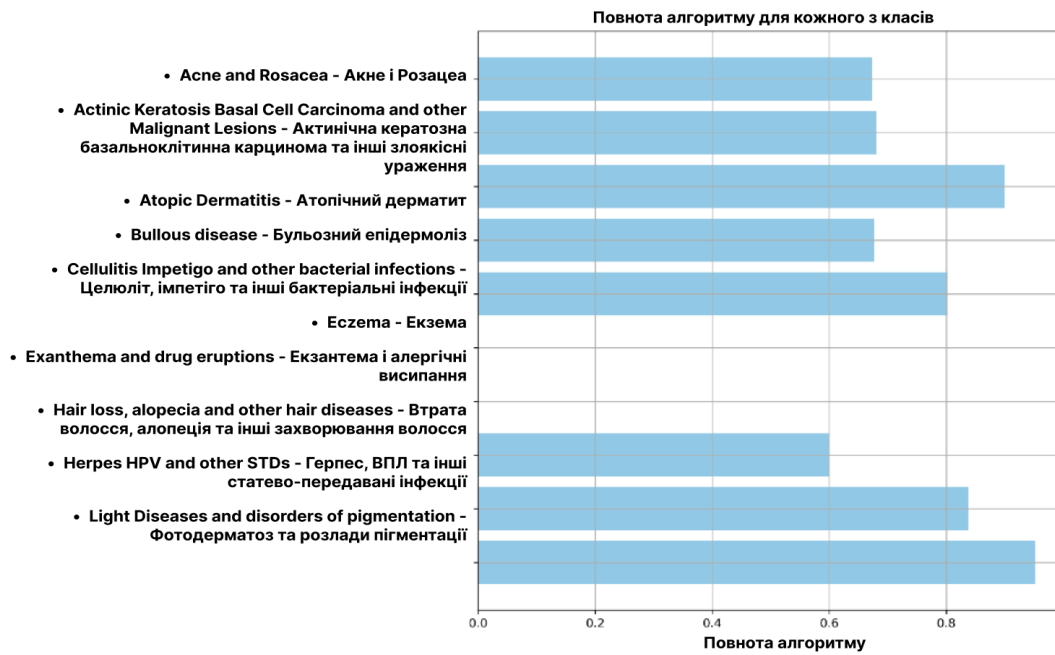


Рисунок 3.3 – Повнота алгоритму ResNet-50 (рисунок створено самостійно)

Середня повнота алгоритму дорівнює 0.76.

З графіку видно що Точність локалізації VGG дорівнює 0.43 на тестовому наборі даних (див. рис. 3.4).

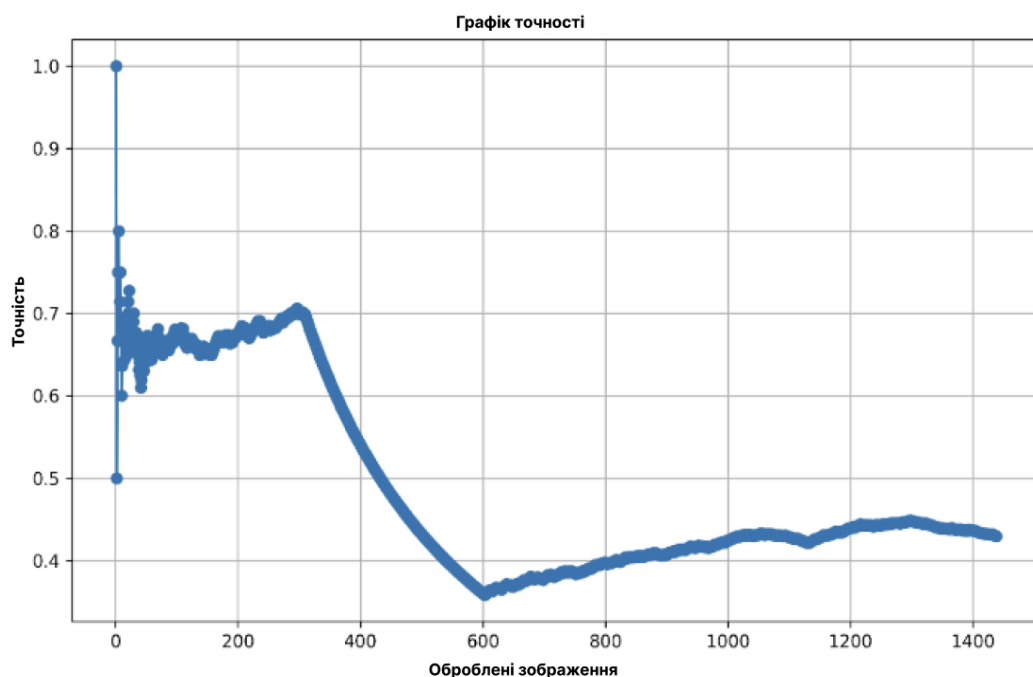


Рисунок 3.4 – Точність локалізації VGG19 (рисунок створено самостійно)

На рисунку 3.5. зображено чутливість по кожній з хвороб для VGG19.

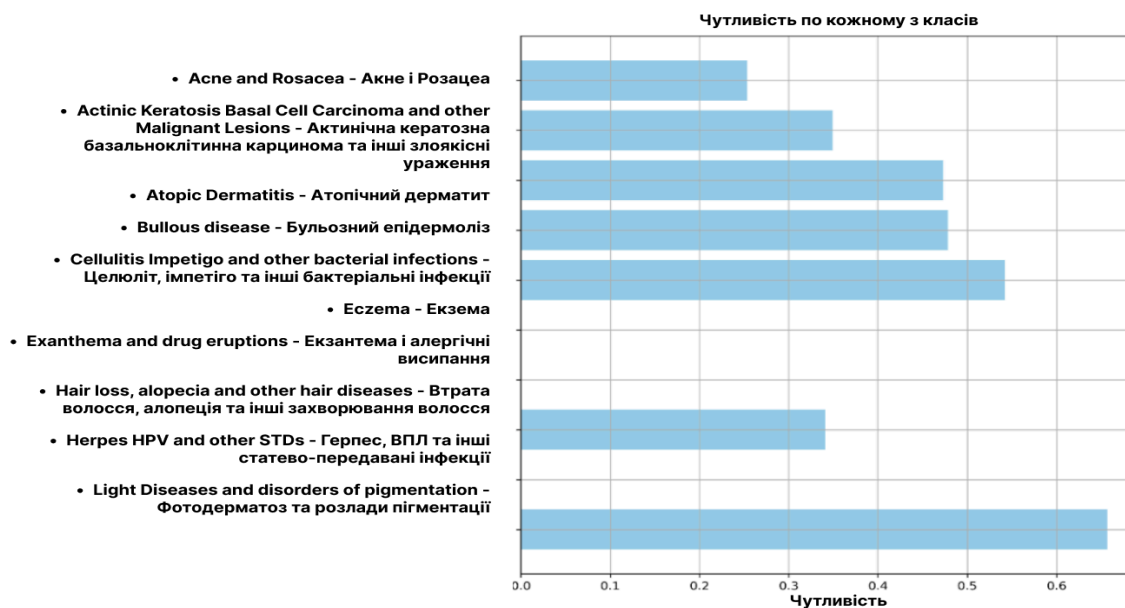


Рисунок 3.5 – Чутливість VGG19 (рисунок створено самостійно)

Середня чутливість дорівнює 0.44.

На рисунку 3.6. зображено повноту алгоритму по кожній з хвороб для VGG19.

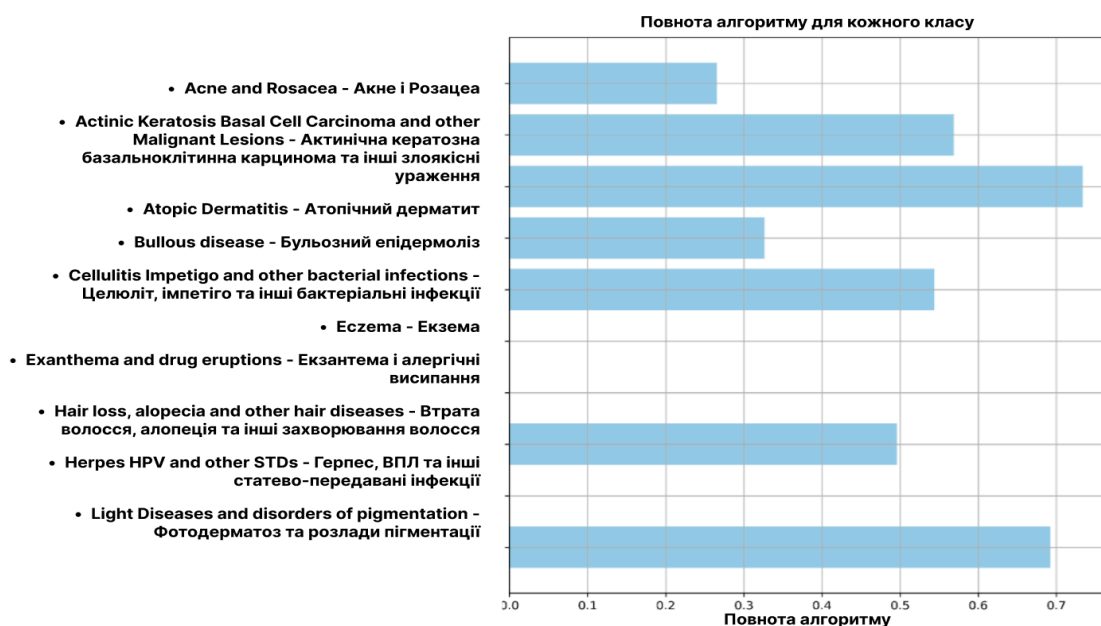


Рисунок 3.6 – Повнота алгоритму VGG19 (рисунок створено самостійно)

Середня повнота алгоритму дорівнює 0.51.

З графіку видно що Точність локалізації DenseNet дорівнює 0.76 на тестовому наборі даних (див. рис. 3.7).

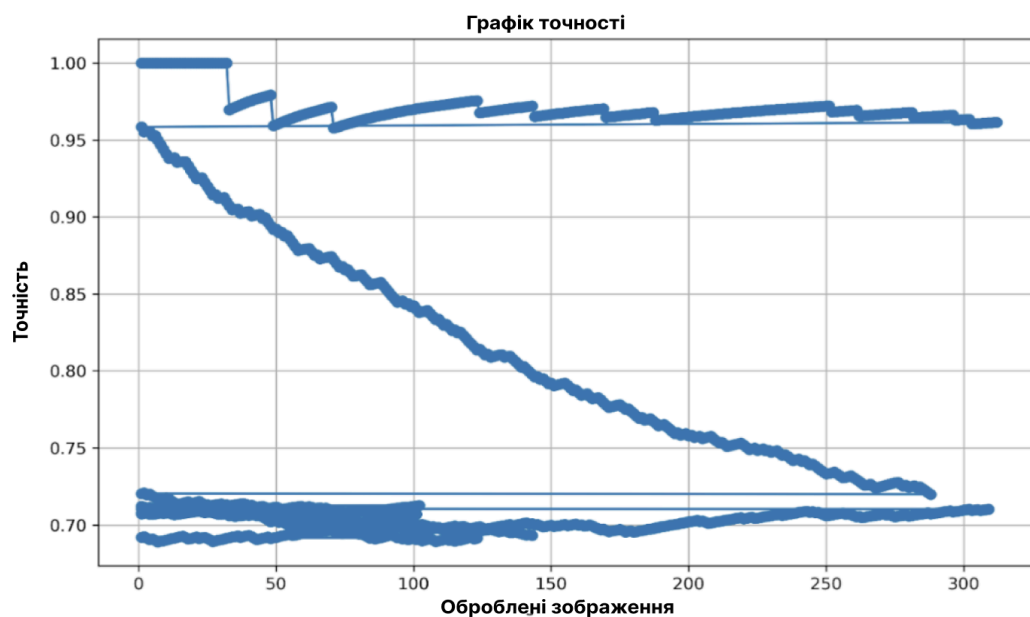


Рисунок 3.7 – Точність DenseNet (рисунок створено самостійно)

На рисунку 3.8 зображено чутливість по кожній з хвороб для DenseNet.

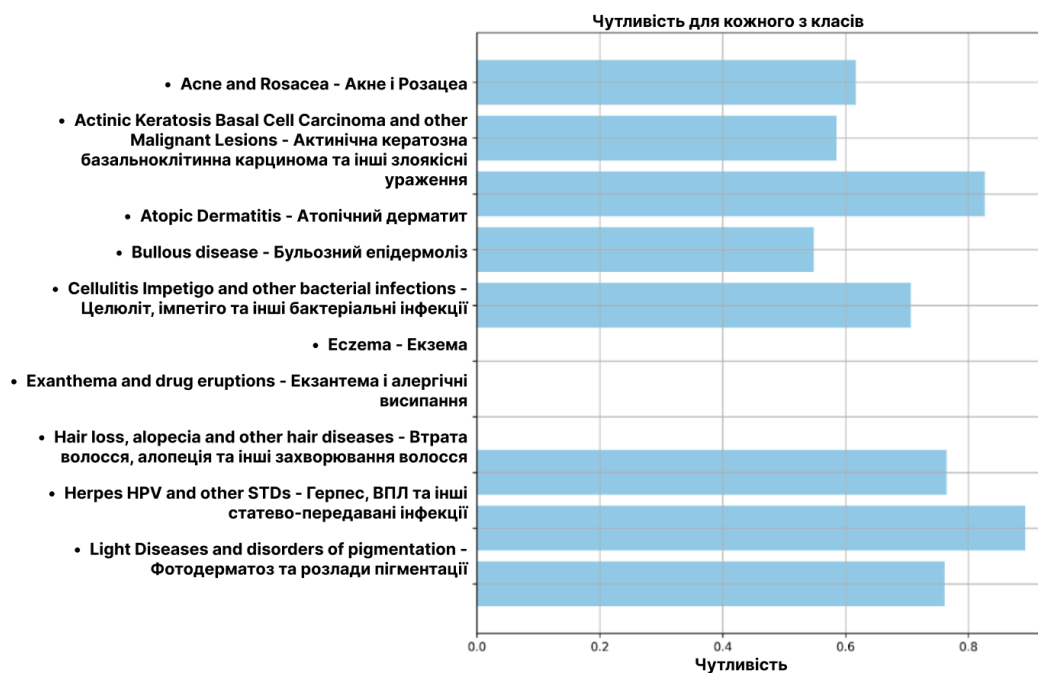


Рисунок 3.8 – Чутливість DenseNet (рисунок створено самостійно)

Середня чутливість дорівнює 0.71.

На рисунку 3.9 зображено повноту алгоритму по кожній з хвороб для DenseNet.

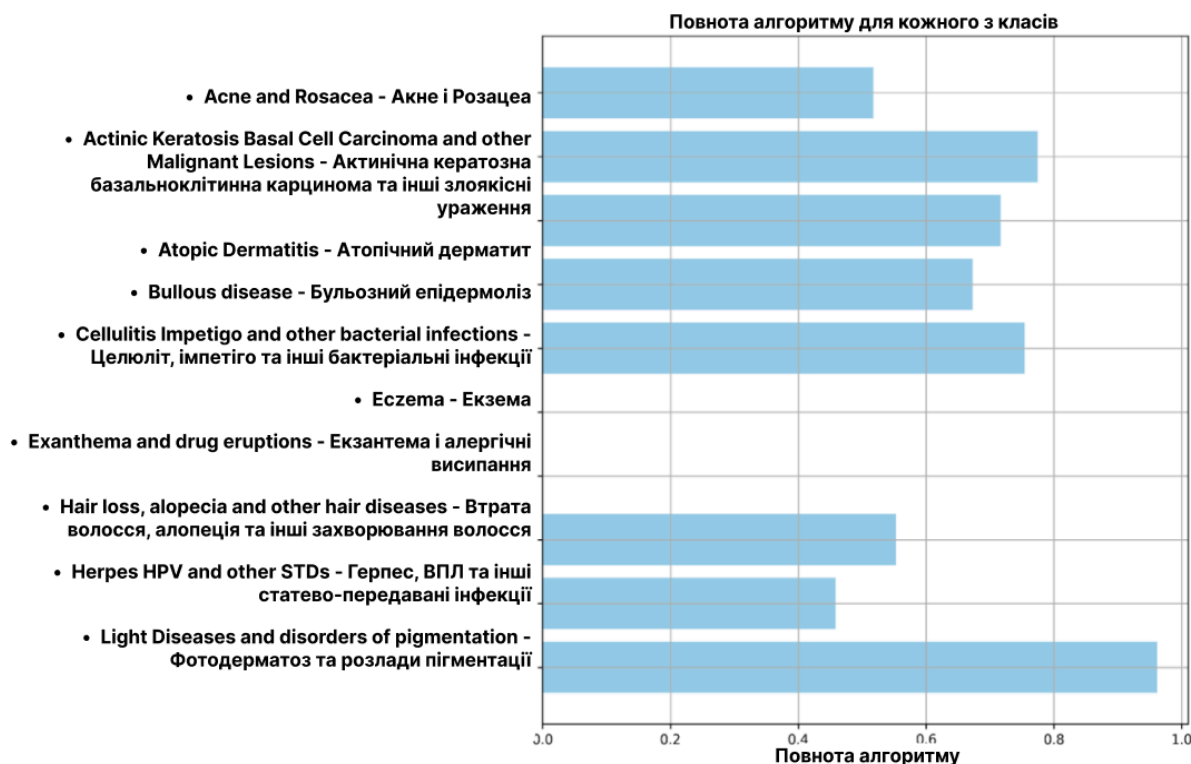


Рисунок 3.9 – Повнота алгоритму DenseNet (рисунок створено самостійно)

Середня повнота алгоритму дорівнює 0.67.

Далі було проведено заміри комбінованого алгоритму який бере усереднені значення кожної нейронної мережі під час виміру щоб отримати більш стабільне значення.

З графіку видно що Точність локалізації Комбінованого алгоритму дорівнює 0.82 на тестовому наборі даних (див. рис. 3.10).

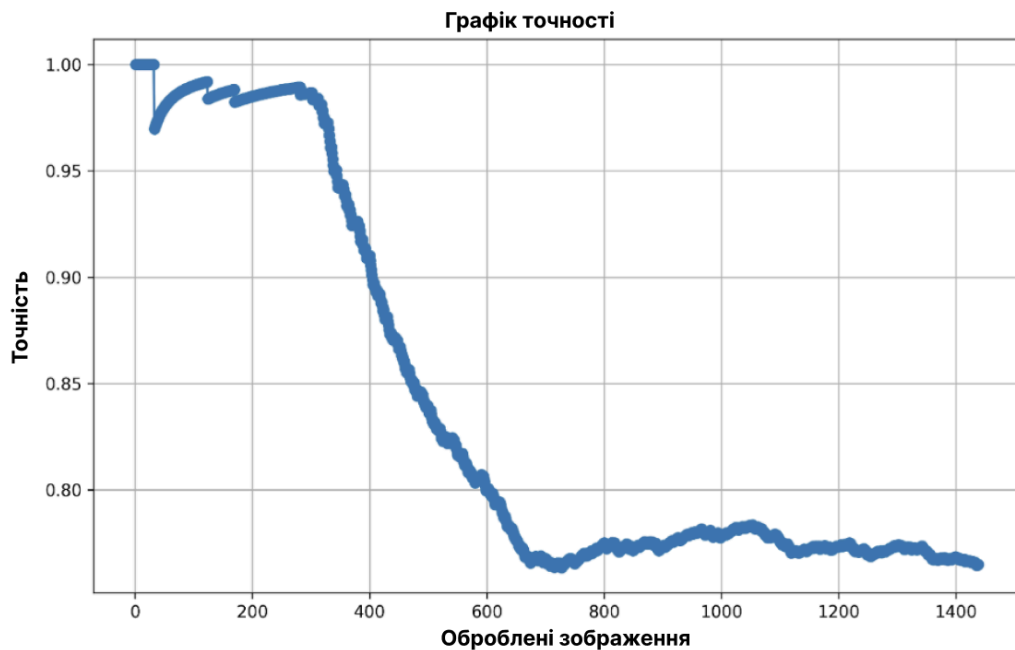


Рисунок 3.10 – Точність локалізації Комбінованого алгоритму (рисунок створено самотійно)

На рисунку 3.11 зображено чутливість по кожній з хвороб для Комбінованого алгоритму.

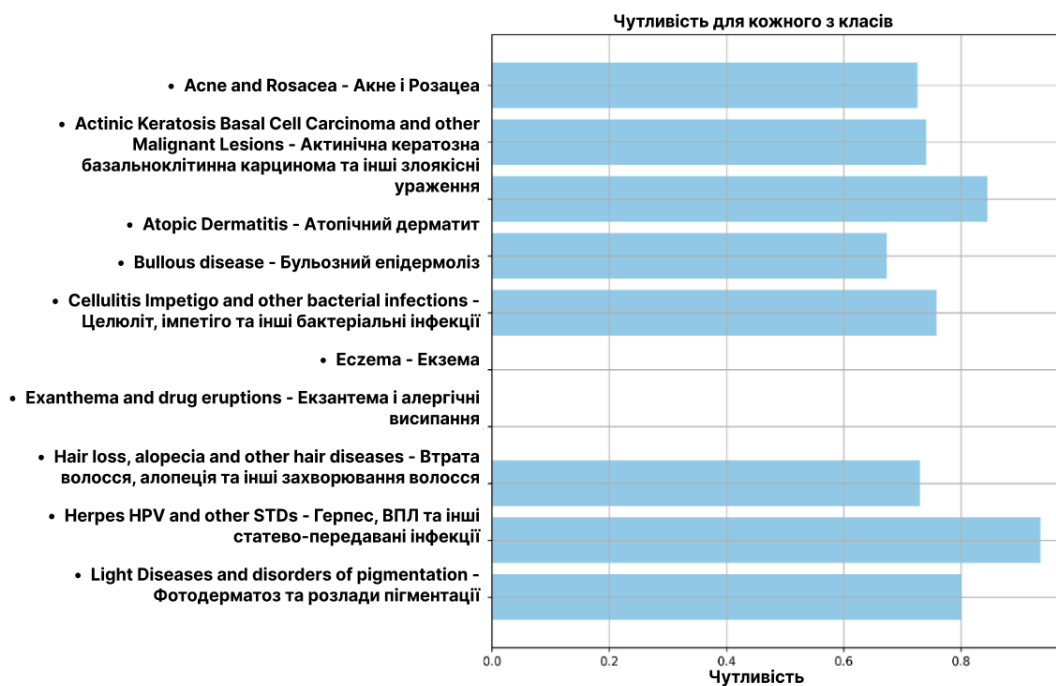


Рисунок 3.11 – Чутливість Комбінованого алгоритму (рисунок створено самостійно)

Середня чутливість дорівнює 0.77.

На рисунку 3.12 зображено повноту алгоритму по кожній з хвороб для Комбінованого алгоритму.

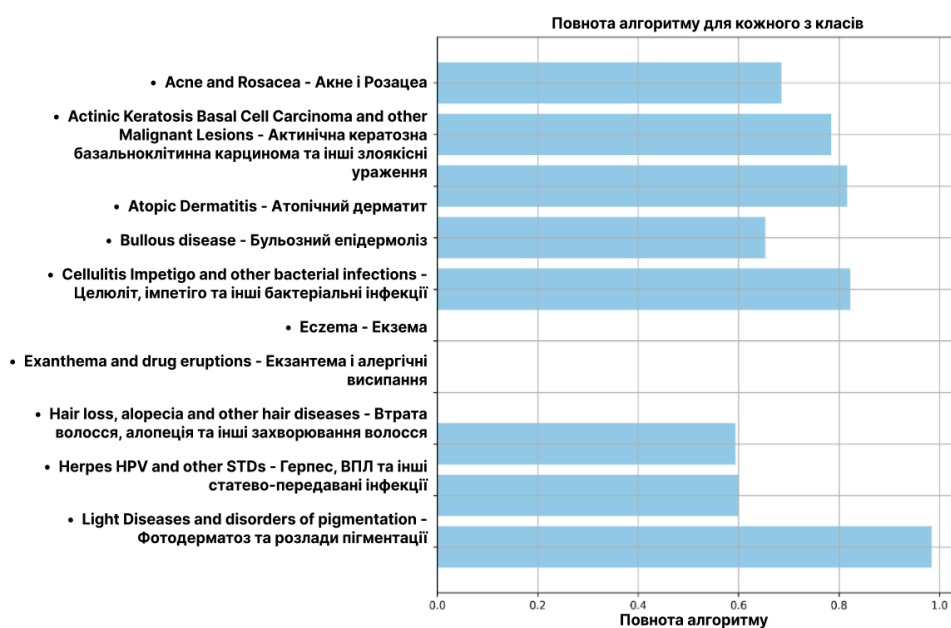


Рисунок 3.12 – Повнота алгоритму Комбінованого алгоритму (рисунок створено самостійно)

Середня повнота алгоритму дорівнює 0.74.

Отримавши результати треба провести багатокритеріальний аналіз, отже було створено таблицю яка містить вагові коефіцієнти, а також усі критерії в якості оцінок (див. табл. 3.2).

Таблиця 3.2 – Шкала оцінок результатів експерименту

Нейронна мережа	Швидкість	Повнота алгоритму	Чутливість	Точність локалізації
ResNet-50	4	7	8	7
VGG19	6	5	4	4
DenseNet	5	6	7	7
Комбінований алгоритм	1	7	7	8

Наступним кроком було обрано згорткову модель з ваговими коефіцієнтами, її обрано через те що її перевагою є те що ми можемо забезпечити моделі спрямованість на ті аспекти задачі які є найбільш важливими. Формула для розрахунку результату згортки наведена нижче[9].

$$Z = \max \sum_{j=1}^n \alpha_j \beta_j a_{ij} \quad (3.3)$$

де α_j - нормуючі множники

β_j - вагові коефіцієнти що відображають відносний внесок окремих критеріїв до загального критерію

Вагові коефіцієнти будуть визначені методом простого ранжування[13]. Повнота алгоритму є найбільш важливою для задачі для коректного визначення захворювань, отже вона отримує найвищий пріоритет в 4 очки. Точність локалізації важлива для правильного визначення місця ураження, 3 очки. Швидкість роботи теж має велике значення при обробці великого обсягу даних, 2

очки. Чутливість важлива для виявлення навіть слабких сигналів та ознак якоїсь хвороби, 1 очко.

Далі було розраховано суму очків та отримані наступні коефіцієнти:

- повнота алгоритму: $4/10=0.4$;
- точність локалізації: $3/10=0.3$;
- швидкість: $2/10=0.2$;
- чутливість: $1/10=0.1$;

Таким чином отримуємо наступну таблицю з результатами та ваговими коефіцієнтами.

Таблиця 3.3 – Таблиця з результатами та вагові коефіцієнти

	Швидкість	Точність локалізації	Повнота алгоритму	Чутливість
ResNet-50	4	7	7	8
VGG19	6	4	5	4
DenseNet	5	7	6	7
Комбінований алгоритм	1	8	7	7
Вагові коефіцієнти	0.2	0.3	0.4	0.1

Зважаючи на результати можна побачити що ResNet-50 є найкращим вибором за згортковою моделлю з ваговими коефіцієнтами.

Наступним кроком є розрахунок найкращої моделі за принципом Парето. За принципом Парето треба визначати “лідерів” для кожного критерію та розрахувати загальний бал, обираючи тільки ті моделі які в кожному критерії принаймні такі ж, або вищі ніж інші:

а) повнота алгоритму

- 1) лідери: ResNet-50(7), комбінований алгоритм(7);
- 2) інші: VGG19(5), DenseNet(6);

б) швидкість роботи:

- 1) лідер: VGG19(6);
- 2) інші: ResNet-50(4), DenseNet(5), комбінований алгоритм(1);

в) точність локалізації:

- 1) лідер: комбінований алгоритм(8);
- 2) інші: ResNet-50(7), DenseNet(7), VGG19(4);

г) чутливість:

- 1) лідери: ResNet-50 (8);
- 2) інші: DenseNet(7), VGG19(4), комбінований алгоритм(7);

Зважаючи на результати можна побачити що лідерами ставали:

- ResNet-50, комбінований алгоритм;

- VGG19;
- DenseNet.

Також треба відмітити що ResNet була лідером 2 рази, Комбінований алгоритм теж 2 рази, а VGG19 була 1 раз, за цим можна вважати що ResNet є абсолютним лідером серед наведених мереж.

4 ПРОГРАМНА РЕАЛІЗАЦІЯ

На основі проведеного експерименту було створено веб-застосунок, який дозволяє тестувати кожну модель на практиці. Програмний застосунок розроблений за допомогою Python fast-api та JavaScript React. Функціонал веб-застосунку дає можливість завантажувати зображення шкіри та отримувати передбачення і ймовірність кожного захворювання. Серед доступних моделей є ResNet-50, DenseNet, VGG19 та Комбінований алгоритм. Основний вигляд функціоналу показано на рисунку 4.1.



Рисунок 4.1 – Основний вигляд Web-застосунку

У процесі тестування було встановлено, що ResNet-50 виявилася найбільш точною моделлю. Вона найкраще розпізнавала різні види захворювань шкіри з високим рівнем вірогідності. Водночас, Комбінований алгоритм виявився найбільш стабільним, забезпечуючи надійні результати навіть за наявності варіативності вхідних зображень. Модель VGG19 продемонструвала найгірші результати, часто допускаючи помилки або не надаючи точних передбачень.

Важливо зазначити, що проблема розпізнавання захворювань шкіри є досить складною. Завантажене зображення має вирішальне значення, оскільки від якості фото, виділеної ділянки та інших факторів залежить точність передбачень. Ділянка шкіри, яку потрібно розпізнати, також має велике значення. Наприклад, різні типи шкіри можуть мати свої особливості, які ускладнюють задачу розпізнавання. Деякі хвороби можуть виглядати дуже схожими або взагалі не бути помітними на шкірі, що робить процес розпізнавання ще більш складним.

Складність проблеми також збільшується через варіативність шкірних захворювань, які можуть мати подібні симптоми, але різні причини — від алергічних реакцій до інфекційних захворювань. Тому для досягнення високої точності необхідно враховувати багато факторів, таких як освітлення, фокус, якість камери та конкретні особливості шкіри пацієнта.

Таким чином, веб-застосунок, розроблений на базі Python fast-api та JavaScript React, є потужним інструментом для діагностики шкірних захворювань, який може значно допомогти лікарям у їхній роботі. Однак для досягнення найкращих результатів потрібно забезпечити високу якість вхідних даних і враховувати всі можливі фактори, що можуть вплинути на точність передбачень.

ВИСНОВКИ

Ця робота зосереджена на аналізі нейронних мереж з різною архітектурою у задачі аналізу дерматологічних захворювань. На основі проведеного дослідження можна зробити висновок, що модель ResNet-50, а також комбінований алгоритм з використанням моделей ResNet-50, VGG19 і DenseNet виявилися найефективнішими для завдань дерматологічного дослідження. Їхня висока ефективність пояснюється гнучкістю у регулюванні глибини та здатністю до адаптації під конкретні вимоги задачі та обсяг даних. У рамках дослідження була розглянута структура DenseNet та інших архітектур, таких як ResNet-50 і VGG19. Описано ключові елементи кожної моделі, їхні переваги та недоліки.

Додатково, досліджено використання об'єктних детекторів таких як комбінований алгоритм з використанням моделей ResNet-50, VGG19 і DenseNet, які забезпечують точну локалізацію та класифікацію дерматологічних захворювань. За допомогою цих алгоритмів можна виявляти та класифікувати різні типи дерматологічних захворювань, що робить їх ефективними для широкого спектру завдань у цій галузі.

У висновку, це дослідження надає комплексний погляд на використання нейромереж у дерматологічних дослідженнях, вказуючи на те, що модель ResNet-50 та комбінований алгоритм з використанням моделей ResNet-50, VGG19 і DenseNet можуть служити потужними інструментами для аналізу зображень шкіри та класифікації дерматологічних захворювань.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to Sequence Learning with Neural Networks. *Advances in Neural Information Processing Systems*. Retrieved from arXiv:1409.3215.
2. Abu-Jassar, A. T., Al-Sharo, Y. M., Lyashenko, V., & Sotnik, S. (2021). Some Features of Classifiers Implementation for Object Recognition in Specialized Computer systems. *TEM Journal*, 10(4).
3. Le Lu, Xiaosong Wang, (2019). Deep Learning and Convolutional Neural Networks for Medical Imaging and Clinical Informatics.
4. Nithin Buduma, Nikhil Buduma, Joe Papa (2022). *Fundamentals of Deep Learning*.
5. S Poonkintran, Rajesh Kumar Dhanraj, Balamurugan Balusamy (2023). *Object Detection with Deep Learning Models*.
6. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems*. Retrieved from arXiv:1706.03762.
7. Emre Celebi, Teresa Mendonca, (2018). *Dermoscopy Image Analysis (Digital Imaging and Computer Vision)*.
8. Teik Toe Teoh, (2023). *Convolutional Neural Networks for Medical Applications*.
9. Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. Retrieved from arXiv:1412.6980.
10. Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative Adversarial Networks. Retrieved from arXiv:1406.2661.
11. Гунько Н. А. (2024, March) дослідження методів розпізнавання дерматологічних захворювань за допомогою штучного інтелекту. In the X International Scientific and Practical Conference “Problems and prospects of modern

science and education” (March 12-15, 2024) Stockholm, Sweden. International Science Group. 2024. 330 p.

12. Smelyakov K., Chupryna A., Bohomolov O., Hunko N. The neural network models effectiveness for face detection and face recognition. 2021 IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream). 22 April 2024. 2024. P. 1-7.

13. Arsenov A., Ruban I. Smelyakov K., Chupryna A. Evolution of Convolutional Neural Network Architecture in Image Classification Problems. 2018 ITS. 27 November 2018. 2018. P. 35-45.