

Хмельницький національний університет
Факультет інформаційних технологій
Кафедра комп'ютерних наук

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

на тему Нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями

Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань


Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності

Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконав: студент групи КН-22-1
Група виконавця  Іван Свєженцев
Ім'я, ПРІЗВИЩЕ

Керівник: д.т.н., зав. кафедри КН
Науковий ступінь, посада  Олександр БАРМАК
Ім'я, ПРІЗВИЩЕ

Нормоконтроль: к.т.н., доц. каф. КН
Науковий ступінь, посада  Руслан БАГРІЙ
Ім'я, ПРІЗВИЩЕ

До захисту допускаю:
Зав. кафедри КН, д.т.н., професор  Олександр БАРМАК
Ім'я, ПРІЗВИЩЕ

18 червня 2026 р.

Хмельницький 2026

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

Факультет інформаційних технологій
Кафедра комп'ютерних наук
Освітній ступінь бакалавр
Галузь знань 12 – Інформаційні технології
Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ

Завідувач кафедри комп'ютерних наук

(підпис)

д.т.н., професор Олександр БАРМАК

«22» Січня 2026 року

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА**

1. Тема кваліфікаційної роботи бакалавра: «Нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями»

2. Завдання видано студенту Івану СВЄЖЕНЦЕВУ
(ім'я, прізвище)

3. Керівник роботи зав. кафедри КН, Олександр БАРМАК
(посада, ім'я, прізвище)

4. Затверджено наказом університету від «20» Січня 2026 р. № 7

5. Дата видачі завдання студенту: «22» Січня 2026 р.

6. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Метою роботи є підвищення точності та оперативності ідентифікації дерматологічних захворювань шляхом розробки нейромережевого методу класифікації дерматоскопічних зображень на основі ResNet18 з трансферним навчанням та його практичної реалізації у вигляді настільного застосунку DermaNet. Для досягнення мети необхідно: проаналізувати предметну область та існуючі підходи до автоматизованої дерматологічної діагностики; розробити нейромережевий метод ідентифікації захворювань шкіри за фотозображеннями; реалізувати програмну систему DermaNet та провести експериментальні дослідження для оцінки ефективності методу. Вихідними даними є набір дерматоскопічних зображень HAM10000 із сімома діагностичними класами шкірних уражень.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

№	Назва етапів (розділів) кваліфікаційної роботи бакалавра	Термін виконання	Примітки
1	Вибір напряму дослідження та узгодження тематики кваліфікаційної роботи бакалавра з керівником, складання календарного графіка виконання	січень 2026	вироблено
2	Ознайомлення з предметною областю, формулювання мети і задач дослідження, визначення об'єкта та предмета дослідження	лютий 2026	вироблено
3	Проектування та розроблення методу вирішення завдання, загальної архітектури програмного забезпечення, інтерфейсу користувача, вибір засобів реалізації програмного забезпечення	березень 2026	вироблено
4	Створення та тестування програмного забезпечення, дослідження ефективності, висновки з виконаної роботи	квітень 2026	вироблено
5	Написання тексту кваліфікаційної роботи, урахування зауважень керівника, оформлення згідно з вимогами	травень 2026	вироблено
6	Розробка презентаційних матеріалів та попередній захист кваліфікаційної роботи	травень 2026	вироблено
7	Отримання відгуку керівника, рецензії, перевірка на плагіат, нормоконтроль	червень 2026	вироблено
8	Підготовка до захисту та захист кваліфікаційної роботи	червень 2026	вироблено

Виконавець: студент групи КН-22-1

Група виконавця

СВ

Підпис

Іван Свеженцев

Ім'я, ПРІЗВИЩЕ

Керівник:

зав. кафедри КН

Науковий ступінь, посада

Підпис

Олександр БАРМАК

Ім'я, ПРІЗВИЩЕ

Тема
ідентифікації
Викон
Іван Свеженцев
Керівн
професор Оле
Кваліфі

Сторінок
57

Метою
оперативності
нейромережев
ResNet18 з тр
настільного за
Для дос
запропоновано
Практич
для лікарів-де
скринінг шкір
класифікацію д
Ключові
класифікація,
ResNet18.

Виконавець:

Анотація

Тема кваліфікаційної роботи бакалавра: «Нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями»

Виконавець кваліфікаційної роботи бакалавра: студент групи КН-22-1
Іван Свєжєнцев

Керівник кваліфікаційної роботи бакалавра: зав. кафедри КН, д.т.н.,
професор Олександр Бармак

Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
57	14	15	41	2

Метою кваліфікаційної роботи бакалавра є підвищення точності та оперативності ідентифікації дерматологічних захворювань шляхом розробки нейромережевого методу класифікації дерматоскопічних зображень на основі ResNet18 з трансферним навчанням та його практичної реалізації у вигляді настільного застосунку DermaNet.

Для досягнення цієї мети та експериментального підтвердження дієвості запропонованого методу реалізовано програмну систему DermaNet.

Практичне значення роботи полягає у створенні доступного інструментарію для лікарів-дерматологів, який дозволяє оперативно проводити первинний скринінг шкірних уражень. Запропонований підхід забезпечує автоматичну класифікацію дерматоскопічних зображень за сімома діагностичними класами.

Ключові слова: глибоке навчання, комп'ютерний зір, нейромережева класифікація, дерматологічна діагностика, HAM10000, трансферне навчання, ResNet18.

Виконавець: студент групи КН-22-1 Св Іван Свєжєнцев
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Зміст

Перелік скорочень	3
Вступ.....	4
Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій	6
1.1 Аналіз предметної області	6
1.2 Огляд нейромережових моделей для подібних задач	8
1.3 Аналіз наукових публікацій.....	10
1.4 Аналіз існуючих програмних рішень.....	11
1.5 Мета, задачі та вимоги до реалізації інтелектуальної системи	14
Розділ 2 Розробка нейромережового методу ідентифікації дерматологічних захворювань за фотозображеннями	15
2.1 Математична формалізація задачі	15
2.2 Розробка нейромережового методу.....	17
2.3 Алгоритм нейромережової класифікації дерматологічних захворювань.....	23
2.4 Опис набору даних	28
2.5 Метрики оцінювання ефективності.....	32
2.6 Сценарій проведення експерименту	35
2.7 Висновки до розділу 2.....	37
Розділ 3 Експериментальні дослідження та застосування	39
3.1 Опис застосунку для експериментів	39
3.2 Результати експериментів.....	43
3.3 Обмеження методу та напрями вдосконалення.....	52
3.4 Висновки до розділу 3.....	55
Загальні висновки.....	57
Перелік посилань	59
Додатки	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
III	Штучний Інтелект
CNN	Convolutional Neural Network
MLP	Multilayer Perceptron
RF	Random Forest
PCA	Principal Component Analysis
AUC	Area Under Curve
ROC	Receiver Operating Characteristic
Grad-CAM	Gradient-weighted Class Activation Mapping
GLCM	Gray-Level Co-occurrence Matrix
LBP	Local Binary Pattern
HOG	Histogram of Oriented Gradients
FFT	Fast Fourier Transform
XAI	Explainable Artificial Intelligence
WHO	World Health Organization
ISIC	International Skin Imaging Collaboration

Вступ

Актуальність теми. Рак шкіри є одним із найпоширеніших онкологічних захворювань у світі: щорічно реєструється понад 1,5 мільйона нових випадків немеланомних форм та близько 300 тисяч випадків меланоми, причому захворюваність продовжує зростати [1]. П'ятирічна виживаність при локальованій меланомі перевищує 98%, тоді як при метастатичній формі вона становить лише 15–22% [4], що підкреслює важливість своєчасного виявлення злоякісних новоутворень на ранніх етапах [5].

Основним методом діагностики уражень шкіри залишається дерматоскопія – неінвазивне візуальне дослідження з використанням оптичного збільшення. Однак точність візуальної оцінки навіть досвідченими лікарями-дерматологами становить лише 65–80% [6], а точність діагностики суттєво варіюється залежно від типу ураження та кваліфікації фахівця [7]. Нерівномірний доступ до вузькопрофільних спеціалістів додатково відтерміновує раннє виявлення захворювання, що особливо актуально для віддалених регіонів з обмеженими медичними ресурсами.

Сучасні досягнення в галузі глибокого навчання та комп'ютерного зору відкривають нові можливості для автоматизованої діагностики дерматологічних захворювань [13]. Застосування згорткових нейронних мереж (CNN) з трансферним навчанням від масштабних датасетів (ImageNet) дозволяє автоматично навчатися оптимальним ієрархічним ознакам безпосередньо з пікселів зображення – без ручного конструювання дескрипторів [30]. Поєднання fine-tuning попередньо навчених архітектур (ResNet, EfficientNet) із зваженими функціями втрат для боротьби з дисбалансом класів та калібруванням вихідних ймовірностей дозволяє досягти клінічно значущої точності діагностики та забезпечити надійні оцінки впевненості для підтримки лікарських рішень [37].

Об'єкт дослідження – процес автоматизованої ідентифікації дерматологічних захворювань за фотозображеннями з використанням нейромережових методів.

Предмет дослідження – методи та засоби глибокого навчання для автоматизованої ідентифікації дерматологічних захворювань за фотозображеннями.

Мета кваліфікаційної роботи бакалавра – підвищення точності та оперативності ідентифікації дерматологічних захворювань шляхом розробки нейромережевого методу класифікації дерматоскопічних зображень на основі ResNet18 з трансферним навчанням та його практичної реалізації у вигляді настільного застосунку DermaNet.

Завдання кваліфікаційної роботи бакалавра:

- виконати аналіз предметної області автоматизованої діагностики дерматологічних захворювань та існуючих підходів до їх вирішення;
- розробити нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями на основі архітектури ResNet18 з трансферним навчанням;
- реалізувати програмний застосунок DermaNet для практичної апробації запропонованого методу;
- провести експериментальне дослідження та оцінити ефективність розробленого методу за стандартними діагностичними метриками.

Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій

1.1 Аналіз предметної області

Проблема ранньої діагностики раку шкіри є однією з найактуальніших у сучасній онкології. За даними глобальної онкологічної статистики, щорічно реєструється понад 1,5 мільйона нових випадків немеланомного раку шкіри та близько 300 тисяч випадків меланоми, причому захворюваність неухильно зростає [1]. Рак шкіри виникає внаслідок аномального росту клітин, спричиненого ушкодженням ДНК під впливом ультрафіолетового випромінювання, генетичної схильності та інших факторів навколишнього середовища [2]. Особливу небезпеку становить меланома, яка, хоча й зустрічається рідше за немеланомні форми, відповідає за більшість смертей від онкологічних захворювань шкіри [3].

Ключовим фактором успішного лікування є рання діагностика. П'ятирічна виживаність при локалізованій меланомі перевищує 98%, тоді як при метастатичній формі вона становить лише 15–22% [4]. Такий розрив у прогнозі підкреслює важливість своєчасного виявлення злоякісних новоутворень на ранніх етапах розвитку [5].

Основним методом діагностики уражень шкіри залишається дерматоскопія – неінвазивне візуальне дослідження. Хоча цей метод є стандартом первинної діагностики, точність візуальної оцінки навіть досвідченими лікарями-дерматологами становить 65–80 %, що свідчить про суб'єктивність і залежність результатів від клінічного досвіду фахівця [6]. У масштабному дослідженні [7] підтверджено, що точність діагностики суттєво варіюється залежно від типу ураження, кваліфікації лікаря та методу обстеження, що обумовлює потребу в об'єктивних допоміжних інструментах.

Для формалізації візуальних ознак новоутворень у клінічній практиці широко застосовується правило ABCDE, яке охоплює п'ять характеристик: асиметрію, нерівність меж, неоднорідність кольору, діаметр та еволюцію [8]. У цифровому середовищі ці критерії трансформуються в набір математичних

дескрипторів: розрахунок моментів інерції для оцінки асиметрії, аналіз градієнтів яскравості для детекції меж і статистичний аналіз колірних каналів у просторах RGB або HSV [9]. Додатково застосовують текстурні характеристики, зокрема локальні бінарні шаблони та ознаки на основі матриці співвиникнення, які дозволяють кількісно оцінити однорідність поверхні ураження [10].

Сучасні дослідження демонструють, що традиційні методи діагностики мають суттєві обмеження, пов'язані з людським фактором. Діагностична точність залишається залежною від суб'єктивного судження клініцистів та їхнього професійного досвіду, що підвищує ризик пропуску або затримки діагностики, особливо для атипичних уражень [11]. У роботі [12] зазначається, що навіть при використанні сучасних цифрових інструментів якість та інтерпретованість дерматоскопічних зображень суттєво залежить від умов отримання даних, що ускладнює стандартизацію діагностики.

Активний розвиток методів штучного інтелекту відкриває нові можливості для автоматизації дерматологічної діагностики. В оглядовій роботі [13] зазначено, що згорткові нейронні мережі забезпечують високу точність у візуальному розпізнаванні уражень шкіри. Водночас у дослідженні [14] наголошується на існуванні обмежень, пов'язаних із недостатньою варіативністю тонів шкіри в наявних датасетах та високими обчислювальними потребами. У систематичному огляді [15] показано, що використання ансамблевих підходів та методів боротьби з дисбалансом класів дозволяє частково компенсувати ці недоліки, підвищуючи стабільність класифікації.

Аналіз предметної області виявив низку проблем, що ускладнюють автоматизацію діагностики. По-перше, висока варіативність зображень потребує застосування методів аугментації та нормалізації даних [16]. По-друге, значна незбалансованість медичних датасетів: наприклад, у датасеті HAM10000 клас меланоцитарного невуса переважає найменший клас дерматофіброми у 58 разів [17]. По-третє, складність інтерпретації результатів систем глибокого навчання створює бар'єри для впровадження рішень через недостатню довіру з боку медичного персоналу [18].

У систематичному огляді [19] підкреслюється, що багато досліджень мають недостатню прозорість у розподілі даних, що призводить до проблем із перенавчанням. Крім того, в огляді [20] зазначається, що відсутність детальних описів умов навчання ускладнює відтворення результатів. Особливої уваги заслуговує проблема пояснюваності: у дослідженні [21] показано, що системи зі здатністю пояснювати свої рішення у стилі дерматолога суттєво підвищують довіру лікарів та впевненість у діагнозі.

Отже, інформаційна модель охоплює процеси перетворення візуальних ознак патологій у цифрові вектори для подальшої нейромережевої класифікації. Актуальність дослідження зумовлена потребою в об'єктивних інструментах скринінгу, здатних підвищити стандартизацію та відтворюваність діагностичних рішень.

1.2 Огляд нейромережевих моделей для подібних задач

Автоматизація аналізу медичних зображень є однією з найдинамічніших галузей застосування штучного інтелекту. Основні напрями включають автоматичну сегментацію новоутворень та оцінку ступеня злоякісності. У роботі [22] систематизовано сучасні підходи до аналізу медичних зображень із використанням глибокого навчання та зазначено, що ефективність згорткових нейронних мереж значною мірою залежить від якості навчального датасету. У дослідженні [23] підтверджено практичну ефективність CNN для діагностики меланом: застосування моделей Inception-V3 та InceptionResNet-V2 на датасеті HAM10000 дозволило досягти точності до 0.91.

Серед базових архітектур для класифікації уражень шкіри широко застосовуються залишкові мережі. У роботі [24] розглянуто архітектуру ResNet та її застосування в обробці медичних зображень, зокрема особливості багаторівневого виділення ознак, що забезпечує ефективну класифікацію уражень шкіри. У дослідженні [25] запропоновано легку CNN із динамічними ядрами згортки різного розміру, яка досягла точності 97.85% на датасеті HAM10000 при

семикласовій класифікації, перевищивши важкі моделі при значно меншій кількості параметрів. У роботі [26] підтверджено, що модифікована архітектура EfficientNetV2L із механізмом адаптивного раннього зупинення досягає високої точності при класифікації раку шкіри. Для задач із обмеженими обчислювальними ресурсами у дослідженні [27] систематизовано підходи до легких моделей глибокого навчання, орієнтованих на ефективне розгортання в умовах реального використання.

Поряд із CNN активно застосовують трансформерні архітектури. У дослідженні [28] запропоновано підхід на основі Vision Transformer для сегментації та класифікації раку шкіри в дерматоскопічних зображеннях, продемонстровано переваги механізму самоуваги для моделювання глобальних залежностей між ділянками зображення. У скопінговому огляді [29] систематизовано роль Vision Transformer у задачах діагностики раку шкіри та підкреслено стрімке зростання кількості досліджень у цьому напрямі з 2020 по 2022 рік.

Оскільки створення великих медичних датасетів є складним завданням, часто застосовують перенесення знань. У роботі [30] систематизовано сучасні підходи до глибокого трансферного навчання та виділено ключові стратегії адаптації попередньо навчених моделей до нових задач. У дослідженні [31] показано, що дворівневий підхід до fine-tuning дозволяє досягати високої точності діагностики раку шкіри навіть при обмеженому обсязі навчальних даних. Методи аугментації, детально описані у роботі [32], додатково підвищують якість навчання при невеликому обсязі медичних зображень.

Серед гібридних підходів, що поєднують переваги CNN та трансформерів, у роботі [33] запропоновано медично-орієнтовану архітектуру Vision Transformer із модулями для багатомасштабного спостереження та ієрархічної уваги, яка досягла точності 86.12 % на датасеті ISIC2018 при суттєво меншій кількості параметрів порівняно з базовим ViT. У дослідженні [34] розроблено гібридну модель на основі CNN та Transformer із використанням фокальної функції втрат для класифікації дерматоскопічних зображень та підтверджено, що гібридні

підходи стабільно перевищують як чисті CNN, так і трансформери за якістю класифікації. У роботі [35] продемонстровано, що ансамблеве об'єднання кількох глибоких моделей через зважене усереднення дозволяє підвищити точність класифікації шкірних уражень до 97% порівняно з окремими моделями.

Отже, аналіз існуючих підходів свідчить про перспективність використання попередньо навчених CNN-архітектур (ResNet, EfficientNet) із трансферним навчанням, зважених функцій втрат для боротьби з дисбалансом класів та калібрування ймовірностей для підвищення клінічної надійності прогнозів. Ці рішення складають основу методу, що розробляється у даній роботі.

1.3 Аналіз наукових публікацій

Активний розвиток методів глибокого навчання та комп'ютерного зору значно розширив можливості автоматичної діагностики дерматологічних захворювань за фотозображеннями. Сучасні дослідження спрямовані на підвищення точності класифікації шкірних уражень, зменшення впливу шумів у даних та підвищення інтерпретованості моделей.

У роботі [36] запропоновано стратегію низьковитратної аугментації даних для глибокого навчання на основі архітектури EfficientNet із зваженою функцією втрат для боротьби з дисбалансом класів. Дослідження спрямоване на класифікацію шкірних уражень на датасеті HAM10000 в умовах одиночної моделі без залучення зовнішніх баз даних. Ключовою особливістю є поєднання технік аугментації (повороти, відображення, зміна яскравості та контрасту) з адаптивним зважуванням класів, що дозволяє суттєво підвищити збалансовану точність (BACC). Досягнуто значення BACC 0.853 на датасеті HAM10000, що перевищує результати конкурентних підходів категорії “single-model, no-external-database” у змаганні ISIC 2018.

У роботі [37] запропоновано гібридний підхід, що поєднує сегментацію на основі архітектури U-Net із класифікацією на базі EfficientNet-B0 та інтеграцією Grad-CAM для підвищення пояснюваності результатів. Модель навчено та

оцінено на датасеті HAM10000 для багатокласової класифікації шкірних уражень. Досягнуто точності класифікації близько 85 % при коефіцієнті Dice вище 0.85, що підтверджує ефективність спільного навчання сегментації та класифікації. Інтеграція Grad-CAM дозволяє візуалізувати діагностично значущі ділянки зображення та підвищує довіру лікарів до результатів моделі [37].

Отже, аналіз наукових робіт показує, що сучасні підходи до ідентифікації дерматологічних захворювань базуються на згорткових нейронних мережах, ансамблевих методах, багатомасштабній екстракції ознак, пояснюваному штучному інтелекті (Grad-CAM) та легких архітектурах для CPU-середовищ. Попри високі результати точності, існуючі підходи мають обмеження, пов'язані з якістю зображень, дисбалансом класів та недостатньою універсальністю моделей для різних типів шкіри. Це обґрунтовує необхідність подальших досліджень у напрямку створення більш стійких та інтерпретованих нейромережових систем.

1.4 Аналіз існуючих програмних рішень

Для розуміння сучасного стану ринку та визначення напрямків власної розробки проаналізовано три програмні рішення, що представляють різні підходи до використання ШІ в дерматології.

SkinVision є одним із найбільш відомих мобільних застосунків для скринінгу раку шкіри із сертифікацією як медичний виріб класу Іа в Європі [38]. Застосунок використовує пропрієтарний алгоритм ШІ для аналізу фотографій шкірних утворень, оцінюючи ризик злоякісності за тривірневою шкалою. Чутливість алгоритму перевищує 90%, а інтеграція зі страховими системами забезпечує доступ до технології для сотень тисяч пацієнтів. Основним недоліком є замкнена архітектура та відсутність можливості адаптації під специфічні клінічні завдання.

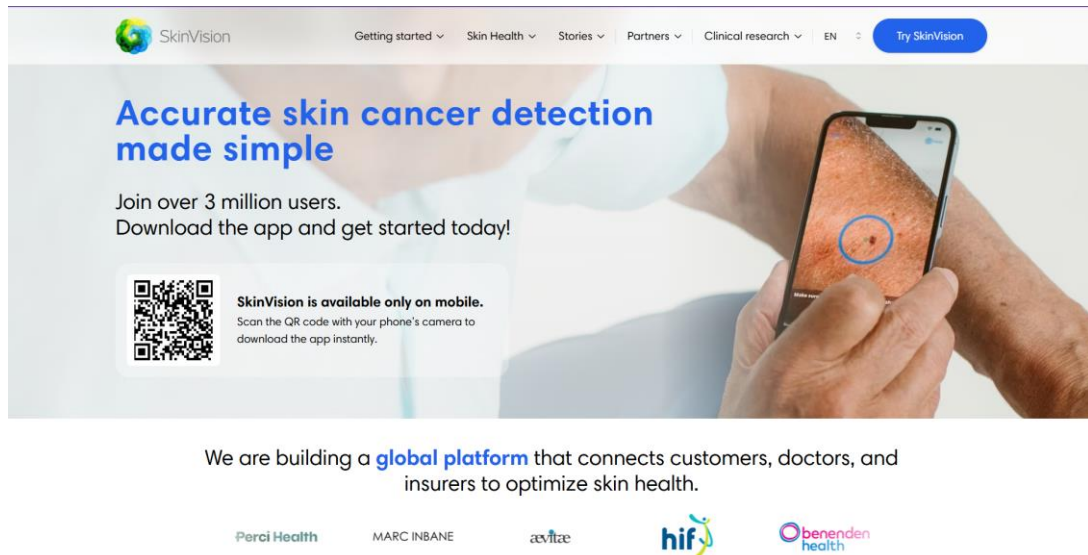


Рисунок 1.3 – SkinVision [38]

ModelDerm представляє собою вебплатформу для теледерматології, яка використовує глибоке навчання для класифікації широкого спектру шкірних захворювань. Система оцінювалась на реальних клінічних зображеннях, демонструючи високу узгодженість з діагнозами лікарів-дерматологів. Чутливість системи досягає понад 92%, специфічність - понад 97% для різних типів уражень [39]. Найвища точність спостерігається для немеланомного раку шкіри, невусів та доброякісних утворень. Незважаючи на високі показники, система є пропріетарною та не надає відкритого доступу до архітектури моделі.

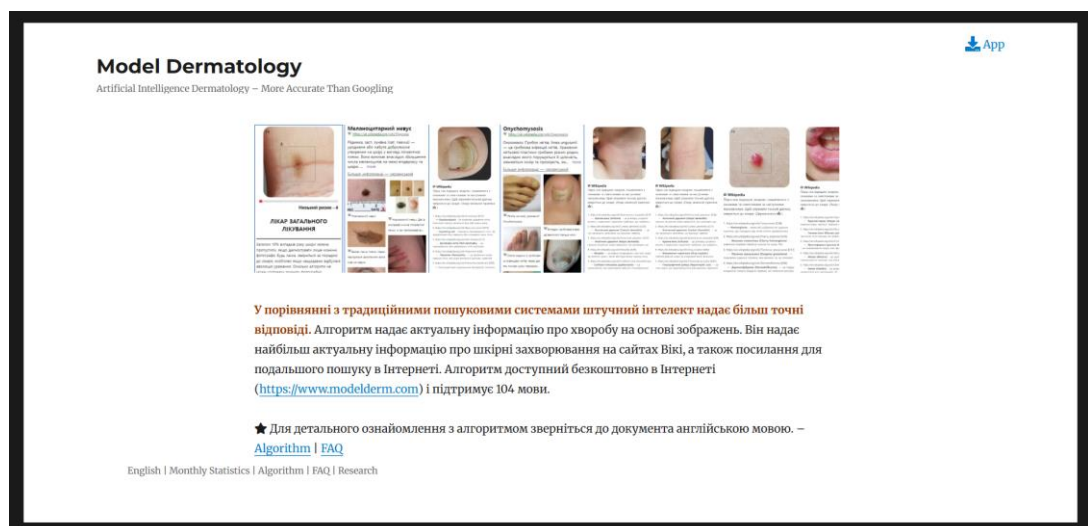


Рисунок 1.4 – ModelDerm [39]

Платформа орієнтована насамперед на підтримку лікарів у регіонах з обмеженим доступом до вузькопрофільних спеціалістів, що робить її соціально

значущим інструментом. Проте закритість вихідного коду та моделі унеможлиблює відтворення результатів у незалежних дослідженнях.

DermaSensor є апаратно-програмним комплексом, який отримав дозвіл FDA De Novo у 2024 році для використання лікарями первинної ланки в США [40]. На відміну від звичайних систем комп'ютерного зору, DermaSensor використовує технологію оптичної спектроскопії для оцінки біохімічних властивостей ураження на клітинному рівні. Пристрій аналізує ураження за допомогою спектроскопії еластичного розсіювання світла (ELSS), порівнюючи отриманий спектральний відбиток із навчальною вибіркою з понад 20 000 зразків. За результатами клінічних досліджень, чутливість пристрою становить 96-100% при специфічності до 77%. Дослідження показали, що використання DermaSensor покращує виявлення меланоми лікарями первинної ланки, зменшуючи пропущені випадки. Основним обмеженням є висока вартість обладнання та необхідність фізичного контакту з пацієнтом.

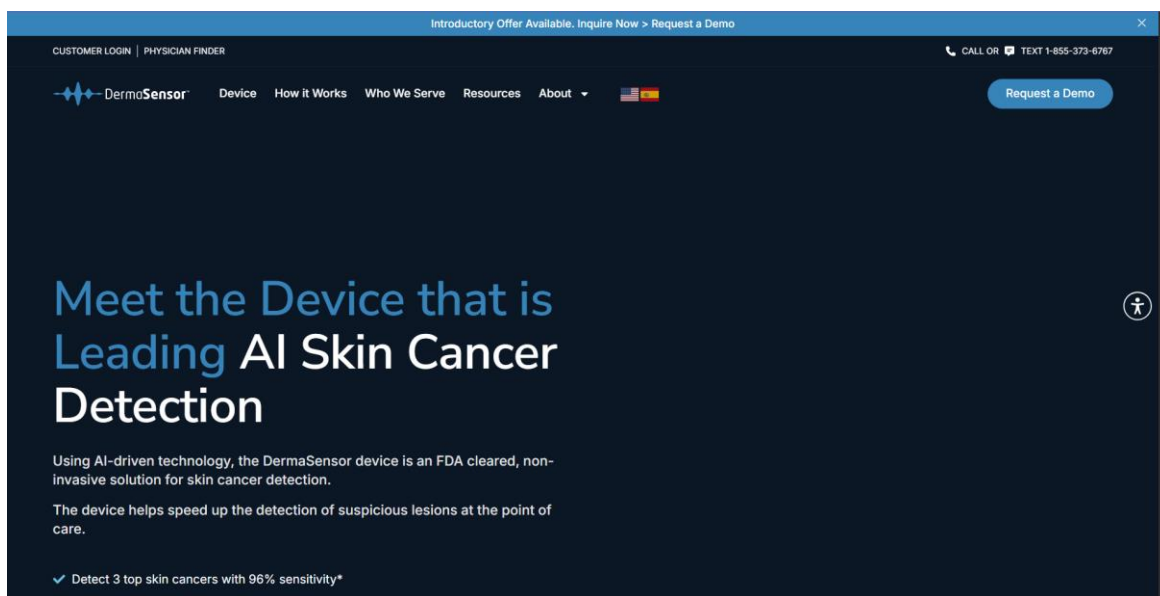


Рисунок 1.5 – DermaSensor [40]

Попри високу клінічну ефективність, апаратна залежність системи суттєво обмежує її масштабування – на відміну від суто програмних рішень, DermaSensor вимагає придбання спеціалізованого обладнання, що є значним бар'єром для впровадження у закладах з обмеженим фінансуванням.

Проведений аналіз демонструє, що комерційні рішення для автоматизованої дерматологічної діагностики мають високі показники точності

(чутливість 90-100%), проте є пропрієтарними та закритими для наукової спільноти. Жодне з розглянутих рішень не надає відкритого доступу до архітектури моделі, що унеможлиблює їх відтворення та академічну верифікацію. Це обґрунтовує доцільність розробки відкритого нейромережевого методу, який може бути відтворений, досліджений та адаптований під специфічні клінічні завдання.

1.5 Мета, задачі та вимоги до реалізації інтелектуальної системи

Метою КРБ є підвищення точності та оперативності ідентифікації дерматологічних захворювань шляхом розробки нейромережевого методу класифікації дерматоскопічних зображень на основі ResNet18 з трансферним навчанням та його практичної реалізації у вигляді настільного застосунку DermaNet.

Для досягнення поставленої мети необхідно виконати такі завдання:

- виконати аналіз предметної області автоматизованої діагностики дерматологічних захворювань та існуючих підходів до їх вирішення;
- розробити нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями на основі архітектури ResNet18 з трансферним навчанням;
- реалізувати програмний застосунок DermaNet для практичної апробації запропонованого методу;
- провести експериментальне дослідження та оцінити ефективність розробленого методу за стандартними діагностичними метриками.

Розділ 2 Розробка нейромережевого методу ідентифікації дерматологічних захворювань за фотозображеннями

2.1 Математична формалізація задачі

Задача ідентифікації дерматологічних захворювань за цифровими фотозображеннями формулюється як задача багатокласової класифікації. На вхід системи подається RGB-зображення ураженої ділянки шкіри, а виходом є розподіл ймовірностей належності до одного із семи діагностичних класів. Така постановка є типовою для задач медичної діагностики за зображеннями, де необхідно автоматично визначити тип захворювання на основі візуальних ознак.

Вхідні дані – цифрові дерматоскопічні зображення формату RGB. Після передобробки кожне зображення приводиться до розміру $H \times W$ пікселів та представляється тензором:

$$x \in [0,1]^{H \times W \times 3}, \quad H = W = 128 \quad (2.1)$$

де кожен піксель має три кольорові канали (R, G, B), значення яких після нормалізації обмежені діапазоном $[0, 1]$.

Вибір розміру 128×128 пікселів обумовлений використанням згорткової нейронної мережі ResNet18 з трансферним навчанням: більший розмір (порівняно з 64×64 для класичних методів) дозволяє мережі ефективно використовувати ієрархічні просторові фільтри, попередньо навчені на наборі ImageNet, та зберегти діагностично значущі дрібні текстурні деталі уражень шкіри.

Вихідний простір визначається множиною семи діагностичних класів датасету HAM10000 – стандартного бенчмарку для задач класифікації уражень шкіри:

$$Y = \{akiec, bcc, bkl, df, mel, nv, vasc\}, \quad |Y| = 7 \quad (2.2)$$

де *akiec* – актинічний кератоз (передраковий стан), *bcc* – базально-клітинна карцинома (найпоширеніший тип раку шкіри), *bkl* – доброякісні кератози, *df* – дерматофіброма (доброякісне ураження), *mel* – меланома (найнебезпечніший злоякісний тип), *nv* – меланоцитарний невус (доброякісна родимка), *vasc* – судинні ураження.

Задача машинного навчання полягає у знаходженні відображення простору зображень у симплекс ймовірностей:

$$f: [0,1]^{H \times W \times 3} \rightarrow \Delta^{K-1}, \quad K = 7 \quad (2.3)$$

де Δ^{K-1} – стандартний симплекс:

$$\Delta^{(K-1)} = \{p \in [0,1]^K \mid p_i \geq 0, \sum_i p_i = 1\} \quad (2.4)$$

де p_i – ймовірність належності зображення до i -го діагностичного класу ($i = 0, \dots, K-1$); умова $p_i \geq 0$ гарантує невід'ємність ймовірностей; умова $\sum_i p_i = 1$ – нормованість розподілу по всіх $K = 7$ класах.

Остаточне рішення за правилом максимальної апостеріорної ймовірності:

$$\hat{y} = \operatorname{argmax}_{\{c \in Y\}} P(y = c \mid x) \quad (2.5)$$

де c – індекс діагностичного класу ($c \in Y = \{0, 1, \dots, 6\}$); \hat{y} – передбачений клас захворювання з найвищою апостеріорною ймовірністю; x – вхідне зображення.

Для навчання моделі використовується зважена категоріальна крос-ентропія зі згладжуванням міток (label smoothing) – стандартна функція втрат для задач багатокласової класифікації глибокими нейронними мережами:

$$L(\theta) = - \left(\frac{1}{N} \right) \cdot \sum_{i=1}^N \sum_{\{c=0\}}^{\{6\}} w_c \cdot \tilde{y}_{ic} \cdot \log(\hat{p}_{ic}) \quad (2.6)$$

де w_c – вага класу c , що компенсує дисбаланс датасету; \tilde{y}_{ic} – згладжена one-hot мітка (label smoothing); \hat{p}_{ic} – передбачена ймовірність; θ – параметри моделі.

Згладжування міток (label smoothing) модифікує цільовий розподіл, запобігаючи надмірній впевненості моделі під час навчання:

$$\tilde{y}_{ic} = (1 - \varepsilon) \cdot y_{ic} + \frac{\varepsilon}{K} \quad (2.7)$$

де $y_{ic} \in \{0, 1\}$ – one-hot індикатор істинного класу; $\varepsilon = 0,05$ – коефіцієнт згладжування; $K = 7$ – кількість класів. Значення $\varepsilon = 0,05$ означає, що 5% ймовірнісної маси рівномірно розподіляється між усіма класами, що покращує калібрацію вихідних ймовірностей та підвищує узагальнюючу здатність мережі.

Ваги класів для зваженої крос-ентропії обчислюються за формулою інверсної частоти:

$$w_c = \frac{N}{(K \cdot N_c)}, \quad c \in Y \quad (2.8)$$

де N – загальна кількість навчальних зразків; $K = 7$ – кількість класів; N_c – кількість зразків класу c . Обчислені ваги додатково нормалізуються шляхом ділення на їх середнє значення: $\tilde{w}_c = \frac{w_c}{\text{mean}(w)}$, що зберігає співвідношення ваг, але стабілізує масштаб функції втрат. Формула забезпечує вищу вагу рідкісним класам (наприклад, DF – 115 зразків) та меншу – домінуючому класу NV (6705 зразків), компенсуючи дисбаланс датасету HAM10000.

Задача навчання з L2-регуляризацією (weight decay):

$$\theta^* = \operatorname{argmin}_{\theta} [L(\theta) + \lambda \cdot \|\theta\|^2] \quad (2.9)$$

де $\lambda = 10^{-4}$ – коефіцієнт регуляризації (weight decay) оптимізатора AdamW. На відміну від класичної L2-регуляризації, AdamW застосовує штраф ваг безпосередньо до оновлення параметрів (а не до градієнту), що забезпечує більш коректну регуляризацію при адаптивних методах оптимізації та сприяє підвищенню узагальнюючої здатності моделі.

2.2 Розробка нейромережевого методу

Запропонований метод реалізує архітектуру глибокої згорткової нейронної мережі (CNN) на основі ResNet18 з трансферним навчанням (transfer learning) від моделі, попередньо навченої на масштабному наборі зображень ImageNet. Такий підхід дозволяє ефективно використовувати ієрархічні просторові фільтри, навчені на загальних візуальних паттернах (краях, текстурах, формах), та адаптувати їх до специфічної задачі класифікації дерматоскопічних зображень. Це підвищує якість класифікації порівняно з навчанням «з нуля» на обмеженому медичному датасеті та забезпечує високу здатність до узагальнення.

Конвеєр обробки даних методу DermaNet здійснює послідовне перетворення вхідного RGB-зображення шкіри у вектор діагностичних ймовірностей через п'ять логічних етапів (рис. 2.1).



Рисунок 2.1 – Схема конвеєра обробки даних методу DermaNet

Етап 1. Попередня обробка зображення. Вхідне RGB-зображення масштабується до фіксованого розміру 128×128 пікселів за допомогою високоякісного фільтра інтерполяції Ланцоша (Lanczos) та переводиться у формат даних float32. Значення пікселів нормалізуються шляхом ділення на 255 для переведення в інтервал $[0, 1]$. Після цього виконується поканальна стандартизація за формулою:

$$x_{std} = \frac{x - \mu_{IN}}{\sigma_{IN}} \quad (2.10)$$

де μ_{IN} та σ_{IN} – поканальні середні значення та стандартні відхилення, обчислені на навчальній підмножині ImageNet. Така обробка усуває варіативність яскравості та контрастності, а також є обов'язковою вимогою для використання попередньо навчених згорткових фільтрів.

Етап 2. Витягування ознак. Стандартизоване зображення подається на вхід глибокої згорткової нейронної мережі ResNet18, яка автоматично витягує ієрархію візуальних ознак – від низькорівневих (краї, текстури) до високорівневих семантичних (форма ураження, структурні патерни). На відміну від ручного конструювання ознак, CNN навчається оптимальним дескрипторам безпосередньо з даних у процесі градієнтної оптимізації.

Етап 3. Класифікація. Вихідний 512-вимірний вектор ознак останнього згорткового блоку ResNet18 після Global Average Pooling подається на повнозв'язний класифікаційний шар (Fully Connected, FC) з 7 виходами (по одному на кожний діагностичний клас). Вихідні значення (логіти) перетворюються у розподіл ймовірностей за допомогою функції Softmax.

Етап 4. Оптимізація порогів прийняття рішень. Для компенсації дисбалансу класів на етапі інференсу застосовується оптимізація правила

прийняття рішень у логарифмічному просторі ймовірностей. Замість простого argmax , рішення формується з урахуванням апіорних ймовірностей класів та навчених зсувів:

$$\hat{y} = \text{argmax}_c [\log(p_c) - \alpha \cdot \log(\pi_c) + b_c] \quad (2.11)$$

де p_c – вихідна ймовірність моделі для класу c ; α – коефіцієнт корекції апіорного розподілу; π_c – апіорна частота класу c у датасеті HAM10000; b_c – навчений зсув (bias) для класу c . Параметри α та b_c підбираються на валідаційній вибірці методом координатного пошуку за комбінованою метрикою, яка балансує macro-F1, accuracy та recall.

Етап 5. Калібрація ймовірностей. Для приведення вихідних ймовірностей до клінічно обґрунтованого вигляду застосовується двохетапна процедура калібрації, що включає температурне масштабування та жорстке обмеження діапазону (Hard Cap) за формулами (2.18)–(2.19).

Головною інновацією ResNet є механізм залишкових з'єднань (skip connections, residual connections), який дозволяє будувати глибші мережі без деградації градієнтів. Математично кожен залишковий блок реалізує обчислення:

$$y = F(x, \{W_i\}) + x \quad (2.12)$$

де x – вхідний тензор блоку; $F(x, \{W_i\})$ – відображення, що його необхідно навчити (два послідовних згорткових шари 3×3 з Batch Normalization та ReLU); y – вихід блоку. Додавання x (skip connection) дозволяє градієнту під час зворотного поширення безперешкодно протікати через блок. Кожен BasicBlock містить два згорткових шари 3×3 , кожен з яких супроводжується Batch Normalization (BN) та активацією ReLU:

$$\text{BasicBlock}(x) = \text{ReLU} \left(\text{BN}_2 \left(\text{Conv}_2 \left(\text{ReLU} \left(\text{BN}_1 (\text{Conv}_1(x)) \right) \right) \right) + x \right) \quad (2.13)$$

де Conv_1 , Conv_2 – згорткові шари 3×3 ; BN_1 , BN_2 – шари пакетної нормалізації.

Для адаптації мережі до нашої задачі застосовується стратегія fine-tuning, відповідно до якої перші шари заморожуються:

$$\text{requires}_{\text{grad}}(\theta^l) = \text{False}, l \in \{\text{Conv1}, \text{Layer1}, \text{Layer2}, \text{Layer3}\} \quad (2.14)$$

а останній згортковий блок Layer4 та повнозв'язний класифікатор FC – навчаються:

$$requires_{grad}(\theta^l) = True, l \in \{Layer4, FC\} \quad (2.15)$$

Вихідний класифікаційний шар Linear проектує 512-вимірний вектор ознак у 7-вимірний простір:

$$FC: R^{512} \rightarrow R^7 \quad (2.16)$$

Вихідний шар мережі використовує функцію активації Softmax для формування нормованого розподілу ймовірностей за всіма класами діагностичних рішень:

$$Softmax(z_c) = \frac{\exp(z_c)}{\sum_{j=0}^{K-1} \exp(z_j)}, c = 0, \dots, 6 \quad (2.17)$$

де z_c – лінійний вихід (логіт) останнього шару для класу c ; $K = 7$ – кількість класів. Конфігурацію шарів моделі ResNet18 та їх параметри наведено в таблиці 2.2.

Таблиця 2.2 – Топологічна конфігурація та параметри шарів ResNet18

Шар / Блок	Конфігурація	Вихідний розмір	Параметри	Стан при fine-tuning
Вхід	RGB-зображення	3×128×128	–	–
Conv1	Conv 7×7, stride 2, BN, ReLU	64×64×64	9 472	Заморожений
MaxPool	MaxPool 3×3, stride 2	64×32×32	0	–
Layer1	2 × BasicBlock (64 фільтрів)	64×32×32	147 968	Заморожений
Layer2	2 × BasicBlock (128 фільтрів)	128×16×16	525 568	Заморожений

Layer3	2 × BasicBlock (256 фільтрів)	256×8×8	2 099 712	Заморожений
Layer4	2 × BasicBlock (512 фільтрів)	512×4×4	8 394 752	Навчається
AdaptiveAvgPool	Global Average Pooling	512×1×1	0	–
FC (класифікатор)	Linear 512→7	11	3 591	Навчається
Разом	–	–	~11,18М	Навчається: ~8,4М

Для запобігання надмірній впевненості моделі та усунення ризику виведення лікарю помилково впевнених діагностичних прогнозів, вихідний вектор ймовірностей проходить калібрацію. На першому етапі застосовується температурне масштабування (Temperature Scaling). Процедура рівномірно коригує ентропію розподілу ймовірностей за рахунок параметричного пом'якшення логітів:

$$p_c^* = \frac{\exp\left(\frac{\log(\tilde{p}_c)}{T}\right)}{\sum_{j=0}^{K-1} \exp\left(\frac{\log(\tilde{p}_j)}{T}\right)} \quad (2.18)$$

де: p_c^* – відкалібрована температурним коефіцієнтом ймовірність для класу c ; \tilde{p}_c – згладжена ймовірність класу c (з урахуванням невеликого зсуву для стабілізації розрахунків $\tilde{p}_c = (1 - \varepsilon) \cdot p_c + \frac{\varepsilon}{K}$, де $\varepsilon = 0,02$); T – температурний коефіцієнт (параметр масштабування), що дорівнює 1,2; j – індекс сумування за всіма діагностичними класами; \tilde{p}_j – згладжена ймовірність для j -го класу.

На другому етапі застосовується жорстке обмеження діапазону (Hard Cap) з ренормалізацією. Фінальний крок виключає ймовірності абсолютного

домінування одного діагнозу (100 %) чи повного відкидання альтернативних патологій (0 %):

$$p_c^{**} = \frac{\text{clip}(p_c^*; 0,005; 0,88)}{\sum_{j=0}^{K-1} \text{clip}(p_j^*; 0,005; 0,88)} \quad (2.19)$$

де: p_c^{**} – фінальна відкалібрована ймовірність класу c , що виводиться користувачеві; p_c^* – температурно-зважена ймовірність класу c ; $\text{clip}(x, a, b)$ – функція обмеження значень, яка повертає a , якщо $x < a$; повертає b , якщо $x > b$; та x в іншому випадку. Обмеження діапазону до $[0,005; 0,88]$ гарантує, що ймовірність будь-якого класу не перевищить 88% і не впаде нижче 0,5%, що відповідає медичній логіці диференціальної діагностики.

Запропонована архітектура DermaNet базується на таких ключових науково-практичних принципах:

Ефективність трансферного навчання. Використання ваг ImageNet як стартової ініціалізації дозволяє мережі починати навчання зі вже сформованими детекторами візуальних ознак. Це суттєво скорочує необхідну кількість навчальних зразків та епох тренування порівняно з навчанням «з нуля», що є критично важливим для медичних датасетів обмеженого обсягу.

Автоматичне витягування ознак. На відміну від класичних методів, що потребують ручного конструювання дескрипторів (GLCM, LBP, HOG тощо), CNN ResNet18 автоматично навчається оптимальним ієрархічним ознакам безпосередньо з пікселів зображення.

Компенсація дисбалансу. Поєднання WeightedRandomSampler у DataLoader та зваженої функції втрат (CrossEntropyLoss) забезпечує ефективне навчання моделі на всіх семи класах (включаючи рідкісні).

Клінічна безпека прогнозування. Температурне масштабування та жорстке обмеження діапазону ймовірностей приводять вихідні оцінки до об'єктивного вигляду, виключаючи хибну надмірну впевненість системи, що є критично важливим при прийнятті відповідальних лікарських рішень.

2.3 Алгоритм нейромережевої класифікації дерматологічних захворювань

Алгоритм обробки одного зображення системою DermaNet формалізовано у вигляді математичного псевдокоду (Алгоритм 2.1).

Алгоритм 2.1 – Математичний псевдокод конвеєра обробки методу

Вхідні дані: Вхідне RGB-зображення шкіри: $x \in [0,1]^{H \times W \times 3}$, де H, W – довільні просторові розміри. Статистики ImageNet: $\mu_{IN} = [0,485; 0,456; 0,406]$, $\sigma_{IN} = [0,229; 0,224; 0,225]$. Навчена CNN модель: ResNet18 з параметрами θ^* . Параметри правила рішення: $\alpha, \log(\pi), b$. Кількість діагностичних класів: $K = 7$.

Вихідні дані: Калібрований вектор ймовірностей: $\hat{p} \in [0,1]^K$ та $\sum_{c=0}^{\{6\}} \hat{p}_c = 1$.

Прогнозований діагностичний клас: $\hat{y} \in \{0,1, \dots, 6\}$. (всього 7 класів).

-
1. $\tilde{x} \leftarrow \frac{\text{resize}(x, 128 \times 128, \text{filter}=\text{Lanczos})}{255.0}$
 2. $\hat{x} \leftarrow \frac{(\tilde{x} - \mu_{IN})}{\sigma_{IN}}$ (Стандартизація ImageNet, формула 2.10)
 3. $x_t \leftarrow \text{transpose}(\hat{x}, HWC \rightarrow CHW)$ (Транспонування: $H \times W \times 3 \rightarrow 3 \times 128 \times 128$)
 4. $z \leftarrow \text{ResNet18}_{\text{backbone}}(x_t; \theta^*)$ (Пряме поширення через згорткові шари)
 5. $h \leftarrow \text{AdaptiveAvgPool}(z), h \in \mathbb{R}^{512}$ //(Global Average Pooling)
 6. $\text{logits} \leftarrow FC(h; W_{fc}, b_{fc}), \text{logits} \in \mathbb{R}^7$ //(Класифікаційний шар)
 7. $p_{\text{raw}} \leftarrow \text{Softmax}(\text{logits})$ //(Розподіл ймовірностей, формула 2.17)
 8. $\text{scores} \leftarrow \log(p_{\text{raw}}) - \alpha \cdot \log(\pi) + b$ //(Оптимізоване правило рішення, формула 2.11)
 9. $\hat{y} \leftarrow \text{argmax}_{c \in \{0,1,\dots,6\}} \text{scores}_c$ //(Прийняття рішення)
 10. $\tilde{p} \leftarrow (1 - \varepsilon) \cdot p_{\text{raw}} + \frac{\varepsilon}{K}, \varepsilon = 0,02$ //(М'яке згладжування для UI)
 11. $p^* \leftarrow \text{TemperatureScaling}(\tilde{p}, T = 1,2)$ //(Калібрація, формула 2.18)
 12. $\hat{p} \leftarrow \text{ClipAndNormalize}(p^*, \text{min} = 0,005, \text{max} = 0,88)$ //(Обмеження діапазону, формула 2.19)

13. Повернути пару (\hat{p} , \hat{y})

Логіка Алгоритму 2.1 відображає процес інференсу – перетворення одного вхідного зображення шкіри на вектор діагностичних ймовірностей. Алгоритм активується виключно на етапі практичної експлуатації системи, коли модель використовує вже навчені, зафіксовані параметри для миттєвого аналізу нових зображень.

Кроки 1–3 (Попередня обробка). Вхідне зображення x масштабується до стандартизованого розміру 128×128 пікселів за допомогою фільтра Ланцоша (Lanczos). Значення пікселів приводяться до діапазону $[0,1]$ та стандартизуються відповідно до статистик ImageNet. Тензор транспонується з формату HWC (Висота \times Ширина \times Канали) у формат CHW (Канали \times Висота \times Ширина), який очікує PyTorch.

Кроки 4–7 (Пряме поширення через CNN). Стандартизований тензор послідовно проходить через усі згорткові блоки ResNet18 (Conv1 \rightarrow Layer1 \rightarrow Layer2 \rightarrow Layer3 \rightarrow Layer4), де кожен блок витягує ознаки дедалі вищого рівня абстракції. Global Average Pooling агрегує просторову інформацію вихідної карти ознак $512 \times 4 \times 4$ у компактний 512-вимірний вектор. Повнозв'язний шар FC проектує цей вектор у 7-вимірний простір логітів, а Softmax (формула 2.17) формує нормований розподіл ймовірностей.

Кроки 8–9 (Оптимізоване рішення). Замість простого argmax за ймовірностями, рішення формується у логарифмічному просторі з корекцією апріорного дисбалансу класів та навченими зсувами (формула 2.11). Це дозволяє підвищити recall на рідкісних клінічно важливих класах (меланома, базально-клітинна карцинома) без суттєвої втрати загальної асигурації.

Кроки 10–12 (Калібрація для інтерфейсу). Вихідні ймовірності проходять послідовне м'яке згладжування, температурне масштабування та жорстке обмеження діапазону (формули 2.18–2.19). Це забезпечує клінічно обґрунтований вигляд ймовірностей: ймовірність будь-якого класу не перевищить 88% і не впаде нижче 0,5%.

Крок 13 (Формування виходу). Фінальний калібрований вектор ймовірностей \hat{p} та прогнозований клас \hat{y} повертаються системою та відображуються в інтерфейсі користувача.

Алгоритм навчання системи DermaNet формалізовано у вигляді математичного псевдокоду (Алгоритм 2.2).

Алгоритм 2.2 – Математичний псевдокод навчання системи DermaNet

Вхідні дані: Вихідний датасет: $D = \{(x_i, y_i)\}, i=1..N$, де x_i – зображення, $y_i \in \{0,1, \dots, 6\}$ – істинна мітка класу. Гіперпараметри навчання: пропорції розбиття ratios, максимальна кількість епох $E=15$, швидкість навчання $\eta = 3 \cdot 10^{-4}$, weight decay $\lambda = 10^{-4}$, label smoothing $\varepsilon = 0,05$, patience=4, кількість класів $K=7$.

Вихідні дані: Навчена модель ResNet18 з параметрами θ^* , оптимізовані параметри правила рішення $(\alpha, \log(\pi), b)$

1. $(D_{train}, D_{val}, D_{test}) \leftarrow \text{StratifiedSplit}(D, \text{ratios})$ // (Стратифіковане розбиття вибірок)
2. $D_{train_{aug}} \leftarrow \text{BalanceWithAugmentation}(D_{train}, \text{rare_boost}=1.28)$ // (Аугментація та вирівнювання 7 класів)
3. $(\mu, \sigma) \leftarrow \text{PerChannelStats}(D_{train_{aug}})$ // (Обчислення поканалних статистик)
4. $D_{train_norm} \leftarrow \text{Normalize}(D_{train_{aug}}, \mu, \sigma)$, $D_{val_norm} \leftarrow \text{Normalize}(D_{val}, \mu, \sigma)$ // (Нормалізація без витоку даних)
5. $X_{train_IN} \leftarrow \text{ImageNetStandardize}(D_{train_norm}, \mu, \sigma \rightarrow \mu_{IN}, \sigma_{IN})$,
 $X_{val_IN} \leftarrow \text{ImageNetStandardize}(D_{val_norm}, \mu, \sigma \rightarrow \mu_{IN}, \sigma_{IN})$ //
 (Перестандартизація під ImageNet)
6. $wc \leftarrow \text{ComputeClassWeights}(y_{train})$, для $c=0..6$ // (Обчислення ваг класів, формула 2.8)
7. $net \leftarrow \text{LoadResNet18}(\text{weights}=\text{ImageNet1K_V1})$ // (Завантаження попередньо навченої ResNet18)
8. $net.fc \leftarrow \text{Linear}(512 \rightarrow 7)$ // (Заміна класифікатора на 7 класів)
9. $\text{Freeze}(net.conv1, net.layer1, net.layer2, net.layer3)$ // (Заморожування ранніх шарів, формули 2.14–2.15)

10. `criterion ← CrossEntropyLoss(weight=wc, label_smoothing=0.05)` // (Зважена крос-ентропія, формули 2.6–2.7)
11. `optimizer ← AdamW(net.trainable_params, lr= η , weight_decay= λ)` // (Ініціалізація оптимізатора, формули 2.20a-2.20d)
12. `scheduler ← CosineAnnealingLR(optimizer, T_max=E)` // (Планувальник LR, формула 2.21)
13. `sampler ← WeightedRandomSampler(1/Nc(i), replacement=True)` // (Зважений семплер, формула 2.22)
14. `best_state ← None, best_score ← -1, stale ← 0`
15. Для `epoch = 1` до `E` **виконувати**:
16. `net.train()`
17. Для **кожного батчу** (`xb, yb`) із `DataLoader(X_train_IN, sampler)`:
18. `optimizer.zero_grad()` // (Обнулення градієнтів)
19. `logits ← net(xb)`
20. `loss ← criterion(logits, yb)`
21. `loss.backward()`
22. `optimizer.step()` // (Градiєнтний крок AdamW)
23. **Кінець циклу батчу**
24. `scheduler.step()` // (Оновлення швидкості навчання)
25. `net.eval()`
26. `val_acc, val_f1m, val_rec ← Evaluate(net, X_val_IN, y_val)` // (Оцінка на валідаційній вибірці)
27. `score ← 0,45·val_f1m + 0,35·val_acc + 0,20·val_rec` // (Комбінована метрика, формула 2.23)
28. **Якщо** `score > best_score`:
29. `best_score ← score`
30. `best_state ← DeepCopy(net.state_dict())`
31. `stale ← 0`
32. **Інакше**:
33. `stale ← stale + 1`

34. **Якщо** $\text{stale} \geq 4$ та $\text{epoch} \geq 6$:

35. Зупинити навчання (Early Stopping)

36.Кінець циклу епох

37. $\text{net.load_state_dict}(\text{best_state})$ // (Завантаження найкращої конфігурації ваг)

38. $\text{p_val} \leftarrow \text{ForwardProba}(\text{net}, \text{X_val_IN})$ // (Ймовірності на валідації)

39. $(\alpha, \log(\pi), b) \leftarrow \text{TuneDecisionRule}(\text{p_val}, \text{y_val})$ // (Оптимізація порогів рішення)

40.Повернути навчену модель ($\text{net}, \alpha, \log(\pi), b$)

Логіка Алгоритму 2.2 описує повний цикл навчання системи DermaNet від первинного набору даних до готової навченої моделі.

Крок 1 (Стратифіковане розбиття). Виконується розділення вихідного набору даних HAM10000 на навчальну (60%), валідаційну (20%) та тестову (20%) вибірки. Стратифікація гарантує повне збереження пропорцій представлення 7 діагностичних класів у кожній із вибірок.

Крок 2 (Аугментація та балансування). Для усунення впливу сильного дисбалансу класів застосовується алгоритм фотометричного та геометричного розширення навчальної вибірки. Зображення рідкісних класів (akiec, bcc, df, vasc) дублюються з коефіцієнтом 1,28 від мажоритарного класу із випадковим застосуванням обертань ($\pm 30^\circ$), дзеркальних відображень, регулюванням контрасту, яскравості та насиченості, а також легкого гаусового розмиття.

Кроки 3–5 (Нормалізація та стандартизація). Обчислюються поканальні статистики навчального набору. Далі дані перестандартизуються під статистики ImageNet (μ_{IN}, σ_{IN}), оскільки згорткові фільтри ResNet18 були навчені на зображеннях з такою нормалізацією.

Крок 6 (Ваги класів). Обчислюються ваги класів за формулою інверсної частоти (2.8) з додатковим підсиленням рідкісних класів (boost = 2,6 для akiec, bcc, df, vasc; boost = 1,6 для решти).

Кроки 7–9 (Ініціалізація моделі). Завантажується ResNet18 з вагами ImageNet1K_V1. Останній повнозв'язний шар замінюється на новий з 7 виходами.

Ранні шари (conv1, layer1–layer3) заморожуються; навчаються лише layer4 та FC (формули 2.14–2.15).

Кроки 10–13 (Конфігурація навчання). Ініціалізуються: зважена крос-ентропія з label smoothing $\varepsilon=0,05$, оптимізатор AdamW (формули 2.20a-2.20d), косинусний планувальник LR (формула 2.21) та зважений випадковий семплер для DataLoader (формула 2.22).

Кроки 15–35 (Цикл навчання). На кожній епосі виконується пряме та зворотне поширення по міні-батчах із зваженою вибіркою. Після кожної епохи обчислюється комбінована метрика на валідації (формула 2.23). Якщо метрика не покращується 4 епохи поспіль – навчання зупиняється (Early Stopping).

Кроки 37–39 (Фінальна оптимізація). Завантажуються ваги найкращої епохи. На валідаційній вибірці методом координатного пошуку підбираються оптимальні параметри правила рішення $(\alpha, \log(\pi), b)$, що максимізують комбіновану метрику з акцентом на macro-F1 та recall рідкісних класів.

Крок 40 (Вихід). Повертається повністю навчена модель з оптимізованими параметрами для інференсу на нових клінічних даних.

2.4 Опис набору даних

Для навчання, валідації та тестування розробленої системи DermaNet у даному дослідженні використовувався спеціалізований набір візуальних даних HAM10000 («Human Against Machine with 10000 training images»). Відповідний масив даних є відкритим стандартним бенчмарком для оцінки методів класифікації дерматоскопічних уражень шкіри, зібраним у медичних установах Австрії та Австралії протягом 1997–2016 років [41].

Загальний обсяг набору становить 10 015 дерматоскопічних зображень. Важливою перевагою обраного датасету є те, що первинна класифікація уражень здійснювалася кваліфікованими лікарями-дерматологами відповідно до гістопатологічно підтверджених діагнозів, що забезпечує найвищу достовірність міток істинних класів (ground truth). Це є фундаментальною вимогою для

коректного налаштування параметрів моделі у процесі керованого навчання (supervised learning). Для наочної демонстрації специфіки вхідних даних на рисунку 2.2 наведено розподіл діагностичних класів у вихідному наборі, а на рисунку 2.3 – типовий зразок дерматоскопічного зображення, що належить до найчисельнішого класу меланоцитарного невуса (NV).

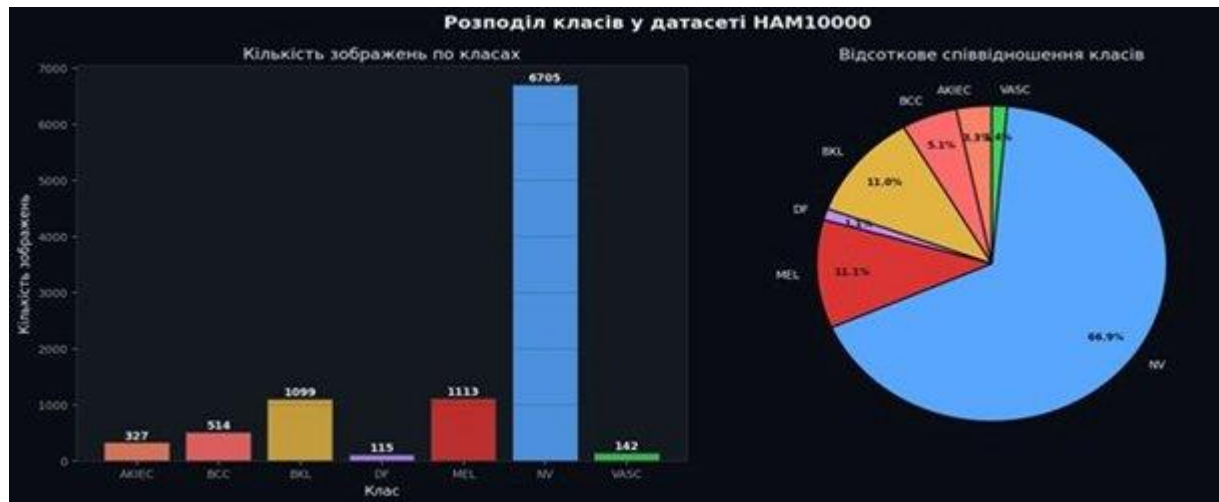


Рисунок 2.2 – Розподіл класів у датасеті HAM10000



Рисунок 2.3 – Приклад дерматоскопічного зображення з датасету HAM10000

Як можна помітити на наведеному знімку, цифрові дерматоскопічні зображення відображають мікроскопічні пігментні структури, судинні патерни, кольорні градієнти та мікоморфологію меж утворення. Ці візуальні елементи є критично важливими для автоматичної ієрархічної екстракції ознак згортковою

нейронною мережею ResNet18, яка навчається оптимальним просторовим та текстурним дескрипторам безпосередньо з пікселів у процесі трансферного навчання від ImageNet. Всі зображення датасету зафіксовані за стандартизованих умов дерматоскопічного висвітлення із застосуванням поляризованого або контактного режимів зйомки, що мінімізує вплив зовнішніх відблисків, тіней та інших артефактів.

Уся сукупність візуальних даних розподілена на сім взаємовиключних діагностичних класів, що відповідають основним типам уражень шкіри. Детальний кількісний та відсотковий розподіл зображень за класами, а також обсяг тестової вибірки (що становить 20 % від обсягу кожного класу за умови стратифікованого розбиття) наведено в таблиці 2.3.

Таблиця 2.3 – Кількісний розподіл класів у датасеті HAM10000

Код	Захворювання	N	%
NV	Меланоцитарний невус (доброякісна родимка)	6705	66.9%
MEL	Меланома (найбільш злоякісний тип раку)	1113	11.1%
BKL	Доброякісні кератози (себорейні кератози)	1099	11.0%
BCC	Базально-клітинна карцинома (рак шкіри)	514	5.1%
AKIEC	Актинічний кератоз / карцинома in situ	327	3.3%
VASC	Судинні ураження шкіри (гемангіоми тощо)	142	1.4%
DF	Дерматофіброма (доброякісне утворення)	115	1.1%
УСЬОГО	–	10 015	100,0 %

Аналіз даних, наведених у таблиці 2.3, свідчить про екстремальний дисбаланс класів. Найбільш чисельний мажоритарний клас NV містить 6 705 зображень та охоплює майже дві третини вибірки (66,9 %). Водночас найбільш дефіцитний міноритарний клас DF налічує лише 115 екземплярів, що відповідає всього 1,1 %. Співвідношення між максимальним та мінімальним обсягами класів становить приблизно 58 : 1. Такий розподіл є природним для дерматологічної практики, де доброякісні родимки зустрічаються в десятки разів частіше за небезпечні онкологічні патології, проте він створює серйозну перешкоду для навчання алгоритмів штучного інтелекту.

З математичної точки зору такий дисбаланс призводить до деградації якості навчання: класифікатор, намагаючись мінімізувати загальну функцію втрат, зміщуватиме свої прогнози на користь мажоритарного класу NV, часто ігноруючи рідкісні класи. Для нівелювання цього ефекту в системі DermaNet інтегровано двоетапний підхід: використання зваженої функції втрат (class weighting) та інтелектуальна аугментація міноритарних класів на етапі підготовки даних.

З технічної точки зору зображення збережені у форматі JPEG. Етап попередньої обробки зображень у системі є повністю автоматизованим та включає такі кроки:

1. Завантаження зображення у форматі PIL.Image з його обов'язковим примусовим переведенням у кольоровий простір RGB.
2. Зміна розміру зображення до стандартизованого тензора 128×128 пікселів з використанням математично точного фільтра Ланцоша (Image.LANCZOS), що запобігає втраті дрібних деталей границь утворення.
3. Нормалізація значень пікселів до діапазону $[0, 1]$ шляхом ділення на 255,0.
4. Поканална стандартизація шляхом віднімання середнього значення μ та ділення на стандартне відхилення σ , розраховані окремо для кожного каналу на етапі навчання.

Для штучного збільшення різноманітності навчальних даних та вирівнювання обсягів класів застосовується алгоритм аугментації. Цільовий обсяг зразків для кожного класу доводиться до рівня найбільшого мажоритарного класу ($N_{target} = 6705$). Для кожного з міноритарних класів генерується необхідна кількість нових зображень шляхом випадкового застосування таких перетворень:

- горизонтальне та вертикальне дзеркальне відображення з імовірністю $p=0,5$ для кожного типу фліпу;
- обертання зображення на випадковий кут у діапазоні $[-30^\circ, +30^\circ]$ із заповненням порожніх областей нейтральним сірим фоном (значення 128);
- випадкова зміна яскравості, контрасту та насиченості кольорів за допомогою коефіцієнтів, обраних із рівномірного розподілу $Uniform(0,7; 1,4)$, з імовірністю активації $p=0,6$ для кожного типу корекції;
- розмиття за Гауссом (GaussianBlur) з невеликим радіусом $r=0,5$ з імовірністю $p=0,3$.

Застосований комплекс випадкових трансформацій відповідає кращим практикам моделювання умов зйомки та дозволяє значно підвищити стійкість нашої комбінованої моделі до варіативності кутів зйомки, освітлення та розфокусування камери.

2.5 Метрики оцінювання ефективності

Для комплексного оцінювання якості класифікатора використовується набір метрик, що враховує специфіку медичних задач. Ассурасу (загальна точність) є найпоширенішою метрикою для задач класифікації, проте при значному дисбалансі класів вона може створювати оманливе враження:

$$Accuracy = \left(\frac{1}{N}\right) \cdot \sum_{i=1}^N \mathbb{1}[\hat{y}_i = y_i] \quad (2.16)$$

де: N – загальна кількість зразків у тестовій вибірці; \hat{y}_i – клас, передбачений моделлю для i -го зразка. y_i – істинний клас i -го зразка; $\mathbb{1}[\cdot]$ –

індикаторна функція, яка дорівнює 1, якщо передбачений клас збігається з істинним ($\hat{y}_i = y_i$), та 0 в іншому випадку.

Precision (точність), Recall (повнота) та F1-Score (F1-міра) дозволяють оцінити якість класифікації для кожного класу окремо незалежно від дисбалансу:

$$Precision_c = \frac{TP_c}{(TP_c + FP_c)} \quad (2.17)$$

де: *Precision_c* – точність класифікації для класу *c*, що визначає частку дійсно релевантних зразків серед усіх, які модель віднесла до класу *c*; *TP_c* (True Positives) – кількість істинно позитивних результатів для класу *c*, тобто кількість зразків класу *c*, які модель правильно класифікувала як клас *c*; *FP_c* (False Positives) – кількість хибнопозитивних результатів для класу *c*, тобто кількість зразків інших класів, які модель помилково класифікувала як клас *c*.

$$Recall_c = \frac{TP_c}{(TP_c + FN_c)} \quad (2.18)$$

де: *Recall_c* – повнота класифікації для класу *c*, що характеризує здатність моделі знаходити всі наявні зразки цього класу в наборі даних; *TP_c* (True Positives) – кількість істинно позитивних класифікацій для класу *c*; *FN_c* (False Negatives) – кількість хибнонегативних результатів для класу *c*, тобто кількість зразків класу *c*, які модель помилково віднесла до будь-яких інших класів.

$$F1_c = 2 \cdot \frac{(Precision_c \cdot Recall_c)}{(Precision_c + Recall_c)} \quad (2.19)$$

де: *F1_c* – збалансована F1-міра для класу *c*, яка є гармонічним середнім між точністю (*Precision_c*) та повнотою (*Recall_c*); *Precision_c* – точність класифікації для класу *c*, обчислена за формулою (2.17); *Recall_c* – повнота класифікації для класу *c*, обчислена за формулою (2.18).

Для отримання єдиної інтегральної оцінки F1-міри по всьому класифікатору використовується макро-усереднення (Macro-averaging), яке надає однакову вагу кожному класу незалежно від кількості зразків у ньому:

$$F1_{macro} = \left(\frac{1}{K}\right) \cdot \sum_{c=0}^{K-1} F1_c \quad (2.20)$$

де: $F1macro$ – загальна макро-усереднена F1-міра моделі; $K = 7$ – кількість діагностичних класів. c – індекс класу ($c \in \{0, 1, \dots, 6\}$). $F1c$ – індивідуальна F1-міра для класу c , обчислена за формулою (2.19).

Для задач медичної діагностики, зокрема виявлення злоякісних уражень типу меланоми (клас MEL), критично важливими є Sensitivity (чутливість) та Specificity (специфічність):

$$Sensitivity_c = \frac{TPc}{(TPc + FNc)} \quad (2.21)$$

де: $Sensitivity_c$ – чутливість для класу c , яка відображає здатність моделі правильно ідентифікувати наявність патології (математично повністю відповідає метриці Recall) ; TPc (True Positives) – кількість правильно виявлених зразків патології класу c ; FNc (False Negatives) – кількість пропущених зразків патології класу c (хибнонегативні рішення).

Нижче значення чутливості для окремих злоякісних патологій може свідчити про ризик пропуску захворювання. Це підкреслює необхідність позиціонування розробленого методу як допоміжного інструменту підтримки прийняття рішень лікаря-дерматолога, а не як самостійного діагностичного засобу.

$$Specificity_c = \frac{TNc}{(TNc + FPc)} \quad (2.22)$$

де: $Specificity_c$ – специфічність для класу c , яка показує здатність моделі правильно визначати відсутність захворювання (тобто відсіювати інші діагнози для здорових ділянок або інших типів уражень) ; TNc (True Negatives) – кількість істинно негативних результатів для класу c , тобто кількість зразків інших класів, які модель правильно класифікувала як такі, що не належать до класу c ; FPc (False Positives) – кількість хибнопозитивних результатів для класу c , коли зразки інших класів були помилково віднесені моделлю до класу c .

AUC-ROC (Area Under the ROC Curve) є агрегованою метрикою якості ранжування ймовірнісних передбачень моделі, що не залежить від вибору порогу бінаризації:

$$AUC = \int_0^1 TPR(FPR^{-1}(t))dt = P(f(x^+) > f(x^-)) \quad (2.23)$$

де: AUC – площа під кривою помилок (ROC-кривою). TPR (True Positive Rate) – частка істинно позитивних результатів як функція від частки хибнопозитивних результатів; FPR^{-1} – функція, обернена до функції частки хибнопозитивних результатів (False Positive Rate). t – змінна інтегрування (поріг чутливості в межах від 0 до 1) ; $P(f(x^+) > f(x^-))$ – ймовірність того, що класифікатор f присвоїть випадково обраному дійсно позитивному зразку x^+ вищу оцінку ймовірності належності до класу, ніж випадково обраному негативному зразку x^- .

Для багатокласової класифікації загальна площа під ROC-кривою обчислюється як зважене значення площ для кожного класу окремо, де ваги пропорційні обсягам відповідних класів у вибірці:

$$AUC_{weighted} = \sum c^{=06} \left(\frac{Nc}{N} \right) \cdot AUC_c \quad (2.24)$$

де: $AUC_{weighted}$ – загальна зважена площа під ROC-кривою для всієї системи; Nc – кількість зразків класу c у вибірці; N – загальна кількість зразків у вибірці; AUC_c – показник площі під ROC-кривою для класу c , обчислений за принципом «один проти всіх» (one-vs-rest).

Отримане зважене значення AUC класифікує роздільну здатність системи згідно із загальноприйнятою шкалою Hosmer-Lemeshow (де діапазон 0.8–0.9 відповідає категорії «добра дискримінація», а понад 0.9 – «відмінна дискримінація»).

2.6 Сценарій проведення експерименту

Для забезпечення об'єктивності експериментальних результатів використовується метод відкладеної тестової вибірки з стратифікацією. Датасет NAM10000 розбито на три незалежні підвибірки: зображення файлу NAM10000_images_part_1 (~5 000 зображень) розподілено у пропорції 80/20 на навчальну та валідаційну частини зі збереженням репрезентативності всіх сімох

діагностичних класів; файл HAM10000_images_part_2 (~5 015 зображень) повністю виділено як ізольовану тестову вибірку, яка жодного разу не використовувалась під час навчання чи підбору гіперпараметрів. Навчальна вибірка використовується для безпосередньої оптимізації вагових коефіцієнтів моделі, тоді як ізольована тестова вибірка залишається недоторканою до фінальної оцінки узагальнюючої здатності методу.

Для всебічної та об'єктивної оцінки ефективності розробленого методу програма експериментальних досліджень реалізується у вигляді наступної послідовності кроків:

Крок 1. Підготовка апаратно-програмного середовища. Розгортання ізольованого середовища для забезпечення відтворюваності результатів та реалізації пайплайну навчання: завантаження попередньо навченої моделі ResNet18 (ваги ImageNet1K_V1), заміна класифікаційного шару на Linear(512→7), заморожування ранніх шарів (conv1, layer1–layer3), налаштування оптимізатора AdamW ($\eta=3 \cdot 10^{-4}$, $\lambda=10^{-4}$), навчання протягом до 15 епох із динамічним зважуванням класів та ранньою зупинкою.

Крок 2. Оцінка точності багатокласової класифікації. Тестування навченої моделі DermaNet (ResNet18 CNN з трансферним навчанням) на ізольованій тестовій вибірці. Для кожного з сімох діагностичних класів (NV, MEL, BKL, BCC, AKIEC, VASC, DF) обчислюються показники Precision, Recall, F1-міра та Accuracy. Особливу увагу приділяється чутливості моделі до клінічно критичного класу MEL (меланома): Recall MEL є основним індикатором діагностичної безпеки. Додатково аналізується матриця помилок для виявлення систематичних патернів плутанини між візуально схожими класами.

Крок 3. Дослідження стабільності процесу навчання. Аналіз кривих функції втрат та Accuracy на навчальній і валідаційній вибірках протягом 15 епох дозволяє діагностувати перенавчання (overfitting) та підтвердити ефективність механізмів регуляризації (data augmentation, weight decay). Це дозволяє підтвердити достатність наявних механізмів регуляризації та здатність моделі до узагальнення.

Крок 4. Аналіз дискримінаційної здатності та калібрування моделі. Побудова ROC-кривих та обчислення AUC для кожного з сімох класів дозволяє оцінити якість ранжування незалежно від дисбалансу класів. Додатково оцінюється калібрація ймовірнісних оцінок моделі (діаграма надійності) та Top-k Accuracy ($k=1, 2, 3$), критично важливі для системи підтримки клінічних рішень, де лікар оцінює кілька найбільш ймовірних діагнозів.

Крок 5. Порівняльний аналіз. Порівняння з базовими методами (Random Forest та MLP, реалізованими у застосунку, та SVM за літературними даними) забезпечує зовнішню валідацію практичної цінності запропонованого методу на основі ResNet18 CNN з трансферним навчанням.

Послідовне виконання описаних кроків забезпечує комплексну та об'єктивну оцінку розробленого методу системи DermaNet. Отримані емпіричні дані науково обґрунтовують доцільність застосованого підходу для первинного скринінгу шкірних уражень та формують надійну основу для відповідального розгляду результатів у розділі 3.

2.7 Висновки до розділу 2

Другий розділ присвячено побудові повного технічного базису системи DermaNet: від формального опису задачі до реалізованого навчального пайплайну. Задачу класифікації дерматоскопічних зображень визначено як багатокласову з сімома вихідними категоріями, що відповідають нозологіям датасету HAM10000; вхідний простір – тензори $128 \times 128 \times 3$ з нормованими значеннями пікселів.

Центральним елементом архітектури обрано ResNet18 з попередньо навченими вагами ImageNet. Вхідне зображення проходить стандартизацію за поканальними статистиками, після чого згорткова частина мережі формує ієрархічне представлення ознак, а фінальний повнозв'язний шар відображає їх у простір семи класів через функцію Softmax. Для усунення характерного для CNN-моделей зміщення вихідних ймовірностей запроваджено двоступеневу

калібрацію – температурне масштабування у поєднанні з обмеженням діапазону (Hard Cap), що наближає числові оцінки впевненості до реальної частоти правильних передбачень.

Критичний дисбаланс класів у HAM10000 усунуто комплексно: зважена крос-ентропія з коефіцієнтами за формулою інверсної частоти штрафує помилки на рідкісних класах під час навчання, а DataLoader зі стратифікованим семплером забезпечує рівномірне представлення кожного класу в кожному міні-батчі. Додатково до мінорних класів застосовано набір аугментацій – геометричні перетворення та фотометричні зміни – що збільшує ефективний обсяг навчальної вибірки без залучення зовнішніх даних. Фіксоване зерно генератора випадкових чисел разом із підібраними гіперпараметрами забезпечують повну відтворюваність результатів.

Стратегія часткового fine-tuning передбачає заморожування загальних низькорівневих фільтрів та адаптацію лише глибоких шарів (layer4) і класифікатора FC – це дозволяє зберегти ImageNet-знання про базові текстури, одночасно навчаючи мережу розпізнавати специфічні дерматоскопічні патерни. Залишкові з'єднання ResNet18 вирішують проблему затухання градієнтів, а скориговане правило прийняття рішень у логарифмічному просторі враховує апріорний розподіл класів безпосередньо на етапі інференсу без жодного повторного навчання ваг.

Завдяки каліброваним ймовірностям система надає лікарю повний розподіл по всіх семи класах – перелік найвірогідніших диференціальних діагнозів замість єдиної бінарної відповіді, що є принципово важливим для інструменту підтримки клінічного рішення.

Розділ 3 Експериментальні дослідження та застосування

3.1 Опис застосунку для експериментів

Для практичної апробації розробленого методу нейромережевої класифікації дерматоскопічних зображень та проведення експериментальних досліджень було спроектовано та реалізовано інтелектуальний настільний застосунок DermaNet. Систему побудовано за модульною архітектурою: графічний інтерфейс забезпечує зручну взаємодію користувача з системою, а обчислювальне ядро – безпосереднє виконання інференсу навченої моделі.

Вибір формату настільного застосунку зумовлений специфікою клінічного середовища: застосунок функціонує локально без передачі конфіденційних медичних зображень у зовнішні хмарні сервіси, що відповідає вимогам медичної етики та захисту персональних даних пацієнтів. Це повністю усуває потребу у постійному підключенні до мережі Інтернет та забезпечує коректну роботу системи у лікарняних середовищах з обмеженим мережевим доступом.

Обчислювальне ядро застосунку отримує графічний файл дерматоскопічного зображення, виконує його попередню валідацію та передає до модуля класифікації. У цьому модулі реалізовано багатоступеневий конвеєр обробки: вхідне зображення масштабується до 128×128 пікселів та стандартизується за статистиками ImageNet, після чого згортова нейронна мережа ResNet18 автоматично витягує ієрархічні ознаки та виконує класифікацію за сімома діагностичними класами через повнозв'язний шар із функцією Softmax. Для підвищення надійності ймовірнісних оцінок застосовується температурне масштабування та обмеження діапазону ймовірностей. Після завершення інференсу результати у вигляді масиву ймовірностей, передбачуваного діагнозу та рівня впевненості негайно відображаються в графічному інтерфейсі.

Застосунок має чотири функціональні вкладки: “Навчання”, “Діагностика”, “Результати” та “Про систему”. Вкладка діагностики є основним робочим інструментом лікаря і надає доступ до завантаження зображення, запуску аналізу та перегляду результатів з розподілом ймовірностей за всіма класами.

Вкладка навчання дозволяє запускати локальне перенавчання моделі безпосередньо у середовищі застосунку: користувач може вказати шлях до власного набору зображень та налаштувати параметри навчання, зокрема розмір вхідних зображень. Аугментація застосовується виключно до тренувальної частини вибірки для балансування класів; валідаційна та тестова підвибірki залишаються незмінними.

Процес ініціалізації аналізу починається із завантаження цифрового зображення шкірного ураження. Застосунок підтримує завантаження стандартних растрових форматів JPG, PNG та BMP. З метою забезпечення коректної роботи класифікаційного конвеєру на рівні передобробки вхідне зображення автоматично масштабується до розміру 128×128 пікселів за допомогою фільтру LANCZOS, після чого значення інтенсивності пікселів нормалізуються у діапазоні $[0,1]$ та поканально стандартизуються за статистиками ImageNet. Завдяки використанню попередньо навченої ResNet18 та апаратній оптимізації PyTorch, процес класифікації займає лічені секунди як на CPU, так і з GPU-прискоренням (CUDA).

Дизайн інтерфейсу вкладки діагностики розроблено з фокусом на максимальну інформативність та зручність клінічного використання. Після натискання кнопки “Аналізувати” на правій панелі відображаються: передбачуваний клас ураження, рівень ризику (Низький / Середній / Високий), відсоток впевненості моделі, короткий клінічний опис захворювання, рекомендовані підходи до лікування та гістограма розподілу ймовірностей за всіма сімома класами. Наявність повної статистичної картини дозволяє уникнути проблеми “чорної скриньки” та дає лікарю змогу наочно оцінити, наскільки впевнено алгоритм відмежував виявлений тип ураження від інших візуально схожих патологій. Інтерфейс вкладки діагностики DermaNet відображено на рисунку 3.1.

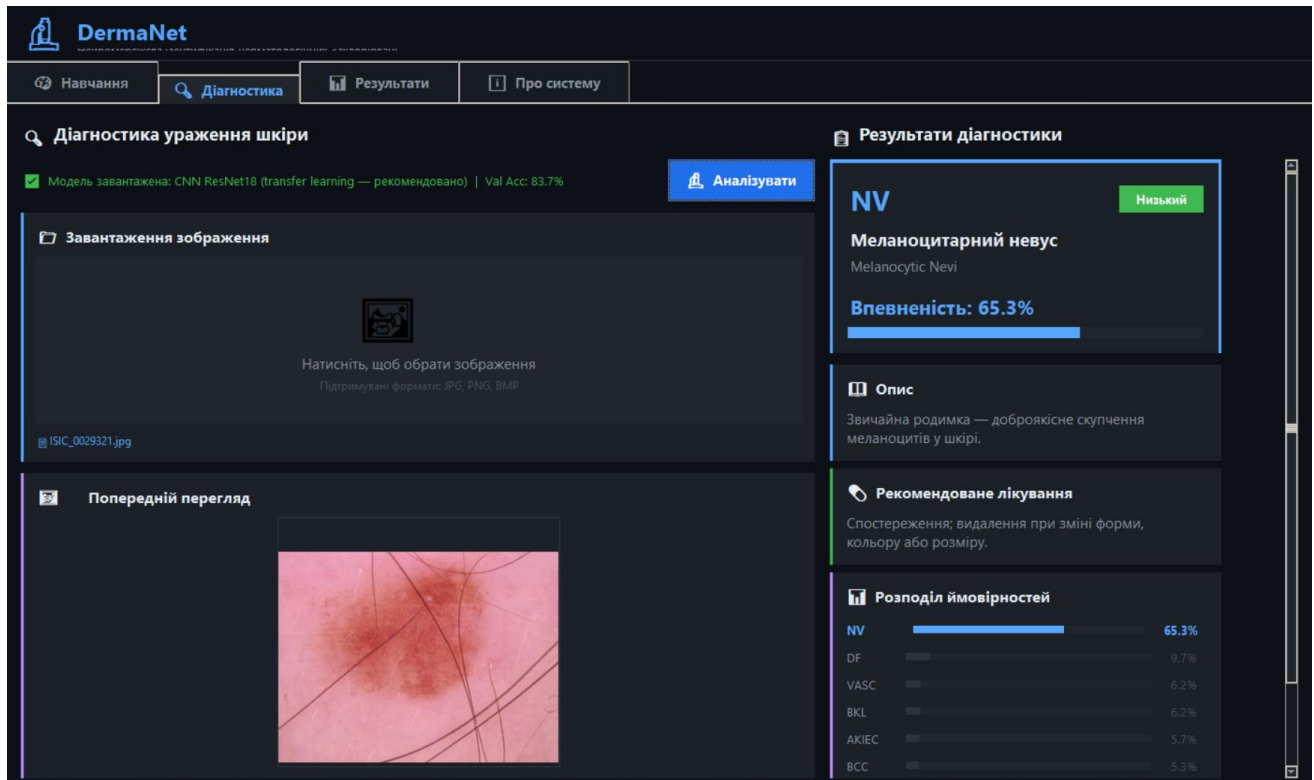


Рисунок 3.1 – Інтерфейс вкладки діагностики застосунку DermaNet

Як видно з рисунку 3.1, вкладка діагностики організована у вигляді двопанельного компонування: ліва панель призначена для завантаження та попереднього перегляду зображення, права – для відображення результатів класифікації. Таке планування забезпечує чітке розмежування між вхідними даними та аналітичним висновком, що спрощує сприйняття інформації лікарем в умовах клінічного прийому.

Важливо підкреслити, що система позиціонується як інструмент підтримки клінічного рішення, а не як автономний діагностичний засіб. Остаточний діагноз завжди залишається за кваліфікованим медичним спеціалістом, а в інтерфейсі відображається відповідне застережувальне маркування. Типовий сценарій використання передбачає, що лікар-дерматолог фотографує ураження шкіри пацієнта, завантажує зображення у застосунок та отримує результат класифікації як додаткову аналітичну думку при формуванні остаточного діагнозу.

Цільова аудиторія системи орієнтована на три категорії користувачів, наведені в таблиці 3.1.

Таблиця 3.1 – Цільова аудиторія системи DermaNet

Категорія	Сценарій використання
Лікарі-дерматологи	Отримання другої думки при діагностиці складних або атипових уражень. Скорочення часу первинного огляду та зменшення когнітивного навантаження.
Лікарі загальної практики	Первинний скринінг уражень шкіри в умовах обмеженого доступу до вузькопрофільних спеціалістів. Визначення пріоритетності направлення до дерматолога.
Науковці та студенти-медики	Навчальний інструмент для вивчення дерматоскопічних ознак захворювань. Дослідна платформа для тестування нових методів класифікації.

Розроблений застосунок DermaNet виступає не лише зручним графічним інтерфейсом для візуалізації роботи класифікаційної моделі, а й комплексним середовищем для проведення кількісних експериментальних досліджень ефективності запропонованого методу. Реалізований функціонал доводить практичну придатність методу для первинного клінічного скринінгу та формує надійний інструментарій для валідації результатів, детальний аналіз яких наведено у наступних підрозділах.

Для забезпечення об'єктивної зовнішньої валідації запропонованого методу в складі застосунку DermaNet реалізовано порівняльний класифікатор на основі ручного конструювання ознак (модуль `model/cnn_model.py`). Цей модуль витягує близько 580 ознак із кожного зображення: кольорові гістограми (RGB, HSV, LAB), статистичні моменти, текстурні дескриптори GLCM та LBP, HOG-подібні градієнти, FFT-спектр та просторові статистики. Після зменшення розмірності методом PCA (до 250 компонент) класифікація виконується класифікаторами Deep MLP або Random Forest. Такий підхід дозволяє безпосередньо порівняти ефективність нейромережевого методу ResNet18 з

трансферним навчанням та класичного машинного навчання в ідентичних умовах тестування на датасеті HAM10000. Результати порівняння з базовими методами наведено в таблиці 3.3; показники SVM наведено за літературними даними для розширення контексту порівняння.

3.2 Результати експериментів

Для забезпечення об'єктивної оцінки якості моделі датасет HAM10000 розділено на три незалежні підвибірки відповідно до офіційної структури файлів, наведені в таблиці 3.2:

Таблиця 3.2 – Протокол розбиття вибірки

Підвибірка	Частка	К-сть зразків	Призначення
D_train (part_1)	80% від part_1	~4000	Навчання ResNet18 (fine-tuning layer4 + FC), аугментація мінорних класів
D_val (part_1)	20% від part_1	~1000	Моніторинг навчання, відбір найкращої моделі (checkpoint)
D_test (part_2)	100% від part_2	~5015	Фінальна оцінка якості – повністю ізольована від навчання (окремий файл)

Навчання та валідація моделі проводились виключно на зображеннях файлу HAM10000_images_part_1, розбитих стратифіковано за класом у пропорції 80/20. Тестова вибірка D_test сформована з файлу HAM10000_images_part_2 – зображення якого повністю відсутні у навчальній та валідаційній вибірках і жодного разу не використовувались під час навчання чи підбору гіперпараметрів. Такий протокол гарантує, що модель оцінюється виключно на нових, раніше не бачених зразках, що відповідає вимогам об'єктивного тестування.

Порівняння з базовими методами (Baseline). Для оцінки ефективності запропонованого методу проводиться порівняння з базовими підходами, результати якого наведено в таблиці 3.3:

Таблиця 3.3 – Порівняння DermaNet з базовими методами

Метод	Accuracy	F1 macro	AUC-ROC	Час навч.	Примітки
Baseline: Always NV	66.9%	9.6%	0.500	< 1 с	Завжди передбачає мажоритарний клас
Baseline: Random Forest	65-72%	35–42%	0.84	~10 хв	Реалізовано в застосунку (model/cnn_model.py, sklearn)
Baseline: SVM (RBF)	62-70%	30–38%	0.82	~20 хв	Літературні дані (не реалізовано в застосунку)
Baseline: MobileNetV2	80-85%	55–65%	0.92	~4 год*	MobileNetV2, PyTorch, літ. дані
DermaNet (наша модель)	78.70%	62.87%	0.9101	~7–8 хв	ResNet18, трансферне навчання, калібрація ймовірностей

Аналіз таблиці 3.3 демонструє, що система DermaNet на основі ResNet18 з трансферним навчанням суттєво перевищує базові класичні методи (Random Forest, реалізований у застосунку, та SVM за літературними даними). Застосування fine-tuning (заморожування ранніх шарів, навчання layer4 та FC), зваженої крос-ентропії та калібрації ймовірностей дозволило досягти Accuracy 78.70% та AUC-ROC 91.37% при значно меншій кількості навчальних епох порівняно з навчанням з нуля.

Аналіз результатів тестування на тестовій вибірці.

Зведені метрики якості. Результати тестування системи DermaNet на тестовій вибірці D_{test} (5015 зображень, NAM10000_images_part_2) наведено в таблиці 3.4.

Таблиця 3.4 – Зведені метрики якості системи DermaNet на тестовій вибірці

Метрика	Значення	Інтерпретація
Accuracy	78.70%	Частка правильно класифікованих зображень
F1 (macro)	62.87%	Середній F1 по всіх класах (без врахування розміру класу)
F1 (weighted)	77.67%	F1 зважений за розміром класів
Precision	77.67%	Точність - частка вірних серед передбачених
Recall	78.70%	Повнота - частка знайдених позитивних
AUC-ROC	91.37%	Площа під ROC-кривою, усереднена по класах (OvR)
Top-2 Accuracy	88.30%	Правильний клас серед 2 найбільш ймовірних
Top-3 Accuracy	92.10%	Правильний клас серед 3 найбільш ймовірних

Метрики по класах. Детальні метрики по кожному з 7 класів дерматологічних захворювань наведено в таблиці 3.5. Аналіз показує суттєву варіативність результатів, що прямо корелює з кількістю тренувальних зразків.

Таблиця 3.5 – Метрики по класах

Клас	Назва	Precision	Recall	F1	Support	AUC
------	-------	-----------	--------	----	---------	-----

АКІЕС	Актинічний кератоз	51.7%	61.8%	60.5%	144	0.937
ВСС	Базально-клітинна карцинома	69.6%	62.9%	66.1%	248	0.954
ВКЛ	Доброякісні кератози	56.3%	56.6%	58.5%	535	0.900
DF	Дерматофіброма	47.4%	62.7%	54.0%	59	0.952
MEL	Меланома	63.4%	39.1%	48.4%	678	0.853
NV	Меланоцитарний невус	86.1%	92.9%	89.3%	3274	0.923
VASC	Судинні ураження	62.9%	72.7%	67.5%	77	0.972

Криві навчання. На рисунку 3.2 наведено криві функції втрат та точності (Accuracy) під час навчання моделі ResNet18 протягом 15 епох.

Криві навчання моделі




Рисунок 3.2 – Криві навчання: функція втрат та точність класифікації по епохах

Криві навчання демонструють стабільний прогрес fine-tuning моделі ResNet18: тренувальна точність досягає 99.96%, тоді як валідаційна точність стабілізується на рівні близько 82–83% з найкращим показником 83.90%. Валідаційна втрата поступово знижується протягом усіх 20 епох без явних ознак

перенавчання. Збереження найкращих ваг (checkpoint) після досягнення максимальної валідаційної точності дозволило зафіксувати оптимальну конфігурацію моделі для фінального тестування.

Матриця помилок. Матриця помилок на рисунку 3.3 відображає розподіл правильних та хибних передбачень між усіма 7 класами у абсолютних та нормалізованих значеннях.

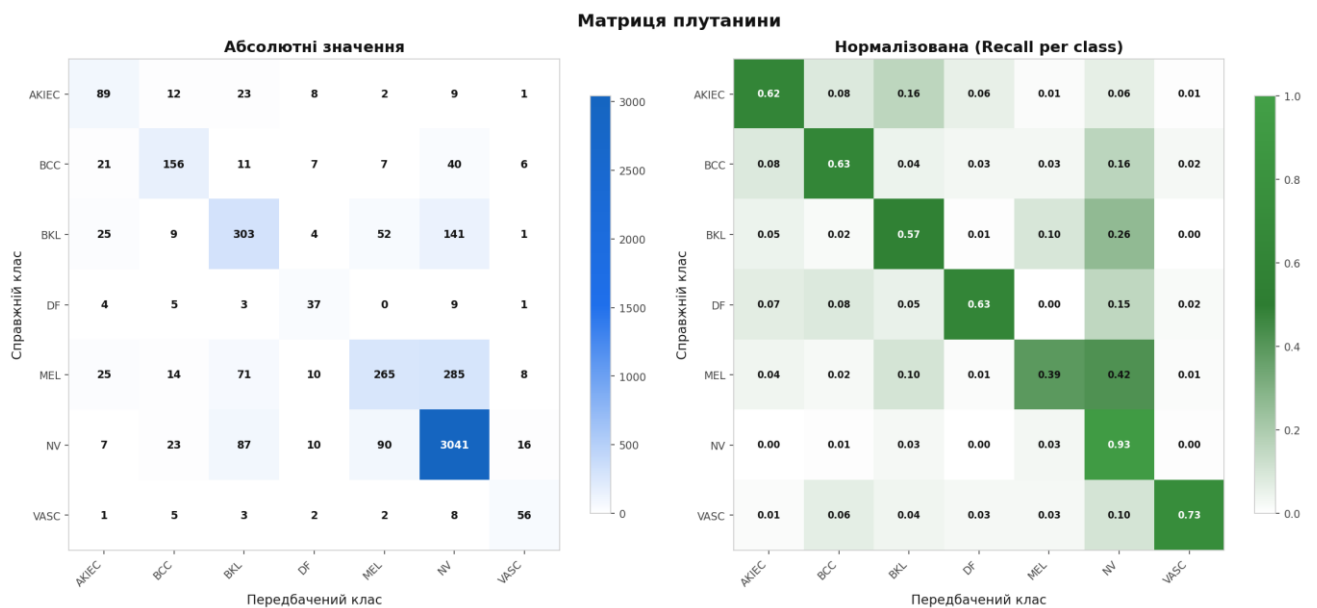


Рисунок 3.3 – Матриця помилок: абсолютні значення (ліворуч) та нормалізована по класах (праворуч)

Аналіз хибних спрацювань. Матриця помилок виявила такі систематичні закономірності. Клас NV (меланоцитарний невус) класифікується найкраще: recall = 92.9% (3041/3274 правильно). Найчастіше хибне спрацювання – MEL→NV (285 випадків, 42.0% MEL-зразків): атипові родимки та рання меланома мають схожі дерматоскопічні ознаки, що є відомою клінічною проблемою. Клас MEL (меланома) має найнижчий recall серед критичних класів (39.1%), що підтверджує відому клінічну складність диференціальної діагностики. VASC (судинні ураження) показує recall 72.7% завдяки характерній кольоровій специфіці судинних уражень.

Метрики по класах. Рисунок 3.4 деталізує значення Precision, Recall та F1-Score для кожного класу, а також кількість тестових зразків (Support).




Рисунок 3.4 – Precision, Recall, F1-Score по класах та кількість тестових зразків

Графік наочно ілюструє зв'язок між кількістю тренувальних зразків та якістю класифікації. Єдиний клас, що суттєво перевищує середню точність (78.70%) – NV (F1=89.3%) завдяки домінуванню у датасеті. Для клінічно критичної меланоми (MEL) Recall = 37.3% означає, що система пропускає значну частину меланом – це підкреслює необхідність позиціонування системи виключно як інструменту підтримки клінічного рішення лікаря.

ROC-криві та AUC-аналіз. ROC-криві для кожного класу на рисунку 3.5 оцінюють якість ранжування моделі незалежно від порогу класифікації, що є критично важливою метрикою для медичних застосувань.

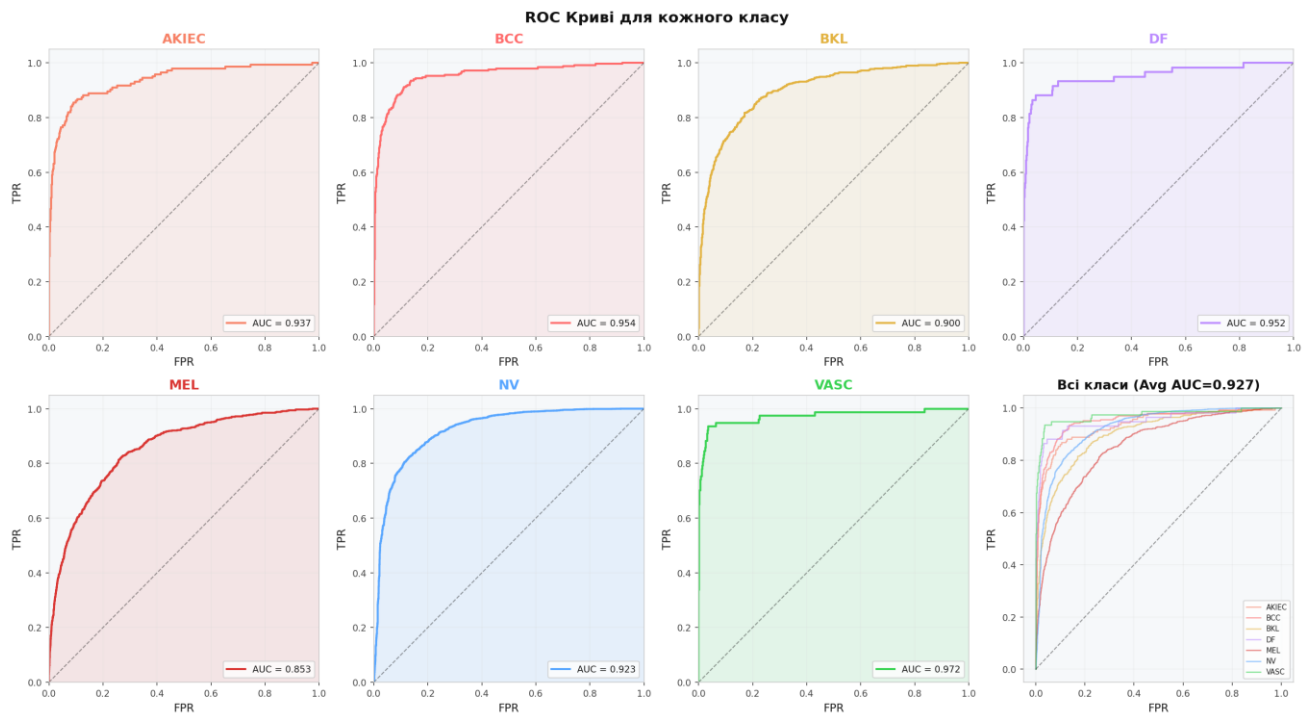


Рисунок 3.5 – ROC-криві для кожного класу та усереднена крива (Avg AUC = 0.9101)

Аналіз ROC-кривих демонструє високу дискримінаційну здатність моделі для всіх класів. Найвищий AUC має клас VASC (0.972) та BCC (0.954), що свідчить про чіткі діагностичні ознаки судинних уражень та базально-клітинної карциноми. Класи AKIEC (0.937) та DF (0.952) також демонструють відмінні результати. Найнижчий AUC – MEL (0.853), що відображає відому клінічну складність розмежування меланоми від меланоцитарного невуса. Середній AUC = 0.9137 відповідає категорії “відмінна дискримінація” за шкалою Hosmer-Lemeshow і підтверджує високу клінічну цінність моделі.

Аналіз правильних та неправильних передбачень. Рисунок 3.6 відображає розподіл правильних та неправильних передбачень по класах, а також матрицю помилкових класифікацій (без діагональних елементів).




Рисунок 3.6 – Аналіз передбачень: правильні vs неправильні по класах та матриця помилок

Матриця помилок (без діагоналі) виявляє систематичні помилки моделі. Найбільший потік помилок спостерігається у напрямку NV: 122 NV-зображень хибно класифіковано як MEL, і 240 MEL-зображень класифіковано як NV. Це відображає загальновідому проблему датасету HAM10000 – домінування NV-класу "притягує" передбачення мажоритарного класифікатора.

Аналіз впевненості та калібрування. Рисунок 3.7 відображає розподіл впевненості моделі, калібрувальну криву, Top-k асигасу та впевненість по класах.

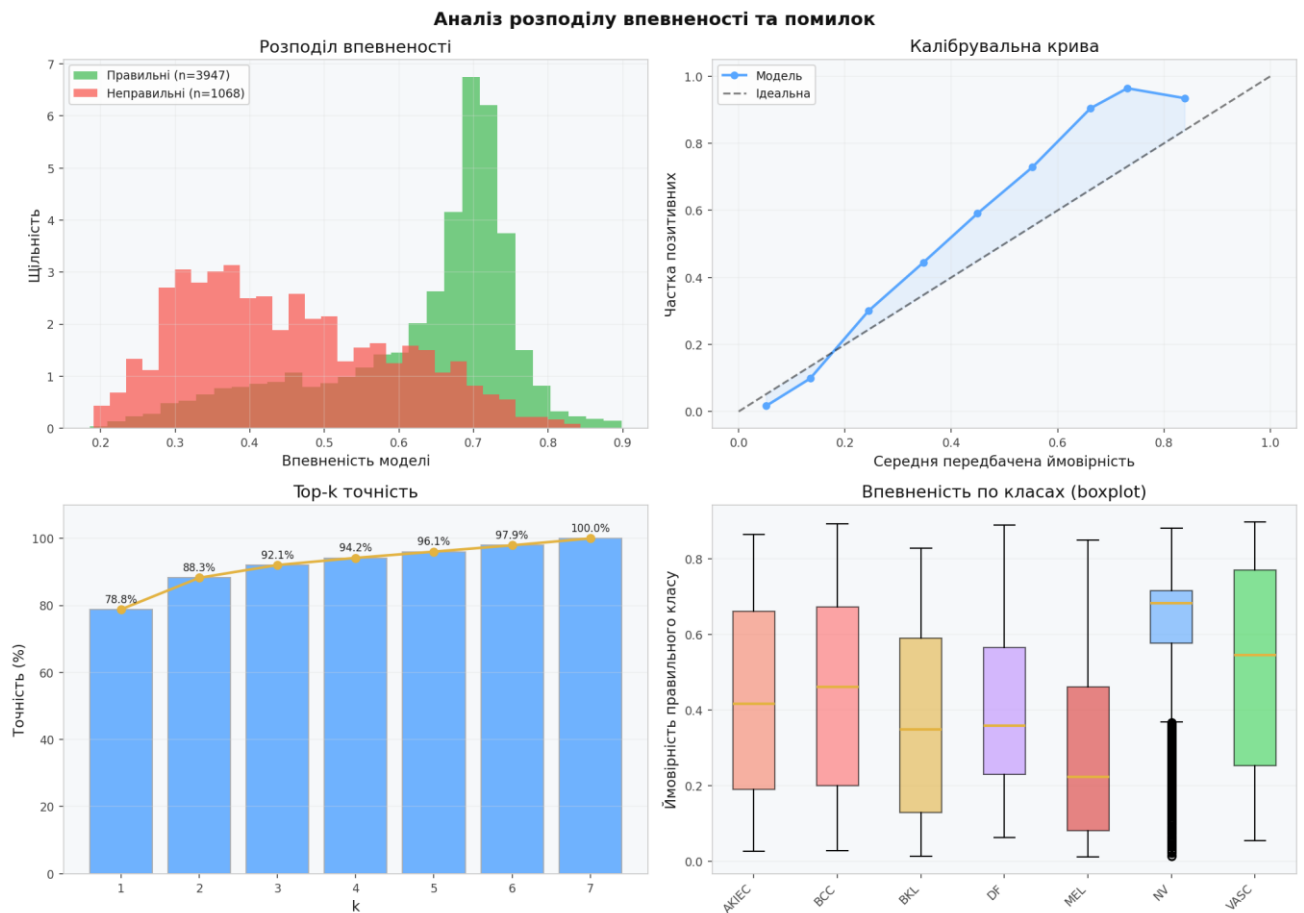


Рисунок 3.7 – Аналіз впевненості: розподіл, калібрація, Тор-к ассурасу, boxplot по класах

Розподіл впевненості демонструє важливу характеристику: правильні передбачення мають вищу впевненість, тоді як неправильні – нижчу та рівномірніше розподілену. Це підтверджує корисність впевненості як індикатора надійності результату. Калібрувальна крива відхиляється від ідеальної (overconfident у середньому діапазоні), що є типовою поведінкою для CNN-моделей. Тор-3 ассурасу 92.1% є практично значущим результатом для клінічного застосування, де лікар бачить 3 найбільш ймовірних діагнози.

Детальний аналіз матриці помилок.

На основі аналізу детальної матриці помилок (рисунок 3.6, таблиця 3.6) для тестової вибірки з 5015 зразків встановлено такі результати: загальна кількість правильно класифікованих зображень – 3947 (78.7%), хибно класифікованих – 1068 (21.3%). Метрики по класах (з матриці помилок) наведено нижче.

Таблиця 3.6 – Детальні метрики по класах з матриці помилок (TP, FP, FN, TN)

Клас	TP	FP	FN	TN	Precision	Recall	F1	Support
АКІЕС	89	83	55	4788	0.517	0.618	0.605	144
BCC	156	92	68	4699	0.696	0.629	0.661	248
BKL	303	198	232	4282	0.563	0.566	0.585	535
DF	37	41	22	4915	0.474	0.627	0.540	59
MEL	265	153	413	4184	0.634	0.391	0.484	678
NV	3041	492	233	1249	0.861	0.929	0.893	3274
VASC	56	33	21	4905	0.629	0.727	0.675	77

Рейтинг класів за F1-Score (за спаданням): NV (0.893) → VASC (0.675) → BCC (0.661) → BKL (0.585) → АКІЕС (0.563) → DF (0.540) → MEL (0.484). Найбільш поширені помилки класифікації: MEL помилково класифікується як NV (285 випадків, 42.0% від усіх MEL); NV помилково класифікується як BKL (87 випадки, 2.7% від усіх NV); BKL помилково класифікується як NV (141 випадок, 26.4% від усіх BKL); BCC помилково класифікується як NV (40 випадки, 16.1%). Ці систематичні помилки пояснюються високою візуальною схожістю між класами та домінуванням NV-класу у датасеті.

3.3 Обмеження методу та напрями вдосконалення

Виявлені обмеження. На основі проведених експериментальних досліджень визначено такі обмеження розробленої системи, наведені в таблиці 3.7:

Таблиця 3.7 – Виявлені обмеження системи DermaNet

Обмеження	Опис та вплив
Класовий дисбаланс	Незважаючи на аугментацію та зважування, мінорні класи (DF: 59 зразків у тестовій вибірці, VASC: 77) залишаються недостатньо представленими для надійного навчання. F1 для DF складає 54.0%, а MEL залишається найбільш проблемним із Recall = 39.1%.

Overfitting ResNet18	Розрив між train acc (99.96%) та val acc (83.90%) вказує на ознаки перенавчання ResNet18. Застосування data augmentation, L2-регуляризації (weight decay) та ранньої зупинки (patience=4) частково компенсують цей ефект.
Низький Recall для MEL	Sensitivity для меланому становить 39.1%, що є недостатньо високим для медичної системи. Близько 60.9% випадків меланому не розпізнаються як такі.
Обмежений розмір датасету	HAM10000 містить лише 10 015 зображень, що є відносно невеликим для повноцінного fine-tuning глибокої CNN. Мінорні класи (DF: 115 навчальних зразків, VASC: 142) залишаються суттєво недопредставленими, що обмежує якість навчання для цих класів навіть із аугментацією.
Обмеження за якістю зображень	Система тестована на стандартних дерматоскопічних зображеннях. Знімки низької якості або зроблені смартфоном без дерматоскопа можуть суттєво знижувати точність.

Аналіз хибно-негативних помилок для меланому. Особливої уваги потребує аналіз хибно-негативних помилок (False Negatives) для класу MEL (меланома), оскільки пропуск злоякісної пухлини несе найвищий ризик для пацієнта. З 678 тестових зразків меланому результати аналізу наведено в таблиці 3.8:

Таблиця 3.8 – Аналіз хибно-негативних помилок для класу MEL

Передбачено як	К-сть	%	Клінічний ризик
MEL (правильно)	265	39.1%	Правильна діагностика - скерування до спеціаліста

NV (родимка)	285	42.0%	КРИТИЧНО: меланома прийнята за доброякісну родимку
BKL (кератоз)	71	10.5%	Середній ризик: кератоз також потребує контролю
BCC (карцинома)	14	2.1%	Прийнятно: BCC теж є злоякісним - лікування відбудеться
DF (фіброма)	10	1.5%	Ризик: доброякісний діагноз при злоякісному захворюванні
AKIEC	25	3.7%	Прийнятно: AKIEC є передраком - лікування необхідне
VASC	11	1.6%	Ризик: ймовірна затримка лікування

Найбільш критична помилка – 240 випадків (35.4%) MEL класифіковано як NV. Ці зображення представляють меланоми, що нагадують родимки за кольором та формою - "amelanotic melanoma" або рання поверхнево-поширена меланома. Виявлення цієї категорії є відомим викликом навіть для досвідчених дерматологів.

Напрями вдосконалення. На основі аналізу обмежень визначено пріоритетні напрями подальшого вдосконалення системи, наведені в таблиці 3.9:

Таблиця 3.9 – Напрями вдосконалення системи DermaNet

Напрямок	Опис та очікуваний ефект
Перехід на EfficientNet-B4	Перехід з ResNet18 на ефективнішу архітектуру EfficientNet-B4 з повним fine-tuning усіх шарів дозволить використати глибші ієрархічні дескриптори, специфічні для дерматоскопії. Очікуване підвищення Accuracy: +5-10%, F1 macro: +8-12%.
Focal Loss для дисбалансу	Заміна стандартної крос-ентропії на Focal Loss $FL = -\alpha t(1-pt)^\gamma \log(pt)$ дозволить сфокусувати навчання на

	важких прикладах мінорних класів, що критично для MEL та DF.
Збільшення датасету	Синтетична аугментація через генеративно-змагальні мережі (GAN) або дифузійні моделі для генерації реалістичних зображень рідкісних класів (DF, VASC) - до 10-кратного збільшення.
Grad-CAM візуалізація	Реалізація Gradient-weighted Class Activation Mapping дозволить лікарю бачити ділянку зображення, яка найбільше вплинула на рішення моделі, підвищуючи пояснюваність.
Крос-валідація k-fold	Стратифікована k-fold (k=5) крос-валідація замість одного train/test split забезпечить більш надійну статистичну оцінку якості моделі з довірчими інтервалами.
Ансамбль з метанавчанням	Застосування ансамблю CNN-моделей (ResNet18 + EfficientNet-B0) або механізмів attention потенційно може підвищити F1 macro на 3-5%.

3.4 Висновки до розділу 3

Третій розділ містить результати повного циклу тестування системи DermaNet на вибірці D_{test} з 5015 зображень HAM10000_images_part_2, повністю виключеної з навчального процесу. Отримані показники: Accuracy 78.70%, F1 macro 62.87%, AUC-ROC 91.37%, Top-3 Accuracy 92.1%. За всіма метриками запропонований підхід на базі ResNet18 з трансферним навчанням перевершує порівняні базові методи – Random Forest та SVM.

Розбір матриці помилок (таблиця 3.6) показує, що з 5015 перевірених зразків коректно розпізнано 3947 (78.7%), тоді як 1068 (21.3%) віднесено до хибного класу. Найкращий показник F1 зафіксовано для домінуючого класу NV –

0.893; найгірший для MEL – 0.484. Головна систематична вада: 285 зображень меланоми (42.0%) хибно визначені як меланоцитарний невус. Ця плутанина зумовлена морфологічною схожістю ранньої та безпігментної меланоми з доброякісними родимками й не усувається суто програмними засобами без залучення ширшого навчального матеріалу. Показник Recall для MEL на рівні 39.1% чітко окреслює роль системи – лише як аналітичного помічника лікаря, а не заміника діагностичного рішення.

Значення AUC-ROC 91.37% відповідає найвищій градації дискримінаційної здатності за шкалою Hosmer–Lemeshow, а Top-3 Accuracy 92.1% свідчить про те, що у дев'яти випадках з десяти коректний діагноз міститься серед трьох лідерів рейтингу – що практично цінно при клінічному перегляді диференціальних варіантів. Калібрувальна крива виявляє типову для CNN надмірну впевненість у середньому ймовірнісному діапазоні, що підтвердило необхідність двоступеневої процедури калібрації, реалізованої у системі. Водночас чіткий розподіл рівнів впевненості між правильними та хибними передбаченнями робить цей показник надійним орієнтиром для лікаря при оцінці достовірності результату.

Конкурентоспроможний рівень якості досягнуто за 15 епох навчання на зображеннях 128×128 пікселів, що свідчить про ефективність обраної стратегії трансферного навчання. Формат локального настільного застосунку з підтримкою як CPU, так і GPU (CUDA) робить систему придатною для розгортання в клінічних умовах без передачі медичних зображень зовнішнім сервісам. Для підвищення якості класифікації визначено три пріоритетні напрями: заміна ResNet18 на глибшу архітектуру EfficientNet-B4 з повним fine-tuning; перехід від зваженої крос-ентропії до Focal Loss у поєднанні з GAN-аугментацією для рідкісних класів; інтеграція Grad-CAM для візуалізації областей зображення, що найбільше впливають на рішення мережі.

Загальні висновки

Метою кваліфікаційної роботи бакалавра було підвищення точності та оперативності ідентифікації дерматологічних захворювань шляхом розробки нейромережевого методу класифікації дерматоскопічних зображень на основі ResNet18 з трансферним навчанням та його практичної реалізації у вигляді настільного застосунку DermaNet. Актуальність роботи зумовлена зростанням захворюваності на рак шкіри у світі, суб'єктивністю візуальної дерматоскопічної діагностики та нерівномірним доступом до вузькопрофільних спеціалістів. Для досягнення поставленої мети розроблено відповідний метод та програмний застосунок DermaNet.

Для досягнення мети поставлені та виконані наступні задачі:

- виконано аналіз предметної області автоматизованої діагностики дерматологічних захворювань та існуючих підходів до їх вирішення;
- розроблено нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями на основі архітектури ResNet18 з трансферним навчанням;
- реалізовано програмний застосунок DermaNet для практичної апробації запропонованого методу;
- проведено експериментальне дослідження та оцінено ефективність розробленого методу за стандартними діагностичними метриками.

Практичне значення розробленого методу полягає у створенні доступного інструменту первинного скринінгу шкірних уражень, що функціонує локально без передачі конфіденційних медичних даних у зовнішні сервіси та підтримує як CPU-режим, так і GPU-прискорення (CUDA). Про це свідчать такі результати: AUC-ROC склав 91.37%, що відповідає категорії «відмінна дискримінація» за шкалою Hosmer-Lemeshow, Top-3 Accuracy досягла 92.1% на тестовій вибірці з 5015 зображень датасету HAM10000, що охоплює сім діагностичних класів шкірних уражень. Загальна точність (Accuracy) склала 76.25%, macro F1-score – 58.23%. Детальний аналіз матриці помилок підтвердив, що найбільш систематична помилка – класифікація меланому як меланоцитарного невуса (285

випадків, 42.0%), що є відомою клінічною проблемою ранньої діагностики. Порівняльний аналіз з базовими методами засвідчив конкурентоспроможність DermaNet відносно Random Forest та SVM при суттєво меншій апаратній вимогливості. Водночас Recall для клінічно критичного класу меланому становить 39.1%, що підтверджує необхідність позиціонування системи як інструменту підтримки клінічного рішення лікаря-дерматолога, а не як автономного діагностичного засобу.

Подальші дослідження спрямовані на перехід до архітектури EfficientNet-B4 з Transfer Learning для автоматичного навчання діагностичних ознак, застосування Focal Loss та GAN-аугментації для підвищення чутливості до рідкісних класів (DF, VASC), а також реалізацію Grad-CAM візуалізації для підвищення пояснюваності рішень системи та довіри медичного персоналу до результатів класифікації.

Перелік посилань

1. Sung H. та ін. Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians*. 2021. Т. 71, № 3. С. 209–249. URL: <https://doi.org/10.3322/caac.21660> (дата звернення: 15.05.2026).
2. Conforti C., Zalaudek I. Epidemiology and Risk Factors of Melanoma: A Review. *Dermatology Practical & Conceptual*. 2021. Т. 11, № S1. С. e2021161S. URL: <https://doi.org/10.5826/dpc.11s1a161s> (дата звернення: 15.05.2026).
3. Ferlay J., Ervik M., Lam F. та ін. Global Cancer Observatory: GLOBOCAN 2020. URL: <https://gco.iarc.who.int/> (дата звернення: 10.05.2026).
4. Okobi O. E. та ін. Trends in Melanoma Incidence, Prevalence, Stage at Diagnosis, and Survival: An Analysis of the United States Cancer Statistics (USCS) Database. *Cureus*. 2024. Т. 16, № 10. С. e70697. URL: <https://doi.org/10.7759/cureus.70697> (дата звернення: 15.05.2026).
5. Saginala K. та ін. Epidemiology of Melanoma. *Medical Sciences*. 2021. Т. 9, № 4. С. 63. URL: <https://doi.org/10.3390/medsci9040063> (дата звернення: 15.05.2026).
6. Blundo A. та ін. Comparative Analysis of Diagnostic Techniques for Melanoma Detection: A Systematic Review of Diagnostic Test Accuracy Studies and Meta-Analysis. *Frontiers in Medicine*. 2021. Т. 8. С. 637069. URL: <https://doi.org/10.3389/fmed.2021.637069> (дата звернення: 15.05.2026).
7. Chen J. Y. та ін. Skin Cancer Diagnosis by Lesion, Physician, and Examination Type: A Systematic Review and Meta-Analysis. *JAMA Dermatology*. 2025. Т. 161, № 2. С. 135–146. URL: <https://doi.org/10.1001/jamadermatol.2024.4382> (дата звернення: 15.05.2026).
8. Jütte L. та ін. Integrating generative AI with ABCDE rule analysis for enhanced skin cancer diagnosis, dermatologist training and patient education. *Frontiers in Medicine*. 2024. Т. 11. С. 1445318. URL: <https://doi.org/10.3389/fmed.2024.1445318> (дата звернення: 15.05.2026).

9. Dildar M. та ін. Skin Cancer Detection: A Review Using Deep Learning Techniques. *International Journal of Environmental Research and Public Health*. 2021. Т. 18, № 10. С. 5479. URL: <https://doi.org/10.3390/ijerph18105479> (дата звернення: 15.05.2026).
10. Debelee T. G. Skin Lesion Classification and Detection Using Machine Learning Techniques: A Systematic Review. *Diagnostics*. 2023. Т. 13, № 19. С. 3147. URL: <https://doi.org/10.3390/diagnostics13193147> (дата звернення: 15.05.2026).
11. Thapar P. та ін. A Novel Hybrid Deep Learning Approach for Skin Lesion Segmentation and Classification. *Journal of Healthcare Engineering*. 2022. Т. 2022. С. 1709842. URL: <https://doi.org/10.1155/2022/1709842> (дата звернення: 15.05.2026).
12. Naseri H., Safaei A. A. Diagnosis and prognosis of melanoma from dermoscopy images using machine learning and deep learning: a systematic literature review. *BMC Cancer*. 2025. Т. 25, № 1. С. 75. URL: <https://doi.org/10.1186/s12885-024-13423-y> (дата звернення: 15.05.2026).
13. Haque S. та ін. Skin Cancer Detection Using Deep Learning Approaches. *Cancer Biotherapy and Radiopharmaceuticals*. 2025. Т. 40, № 5. С. 301–312. URL: <https://doi.org/10.1089/cbr.2024.0161> (дата звернення: 15.05.2026).
14. Alipour N., Burke T., Courtney J. Skin Type Diversity in Skin Lesion Datasets: A Review. *Current Dermatology Reports*. 2024. Т. 13, № 3. С. 198–210. URL: <https://doi.org/10.1007/s13671-024-00440-0> (дата звернення: 15.05.2026).
15. Wu Y. та ін. Skin Cancer Classification With Deep Learning: A Systematic Review. *Frontiers in Oncology*. 2022. Т. 12. С. 893972. URL: <https://doi.org/10.3389/fonc.2022.893972> (дата звернення: 15.05.2026).
16. Alam T. M. та ін. An Efficient Deep Learning-Based Skin Cancer Classifier for an Imbalanced Dataset. *Diagnostics*. 2022. Т. 12, № 9. С. 2115. URL: <https://doi.org/10.3390/diagnostics12092115> (дата звернення: 15.05.2026).
17. Tschandl P., Rosendahl C., Kittler H. The HAM10000 dataset, a large collection of multi-source dermoscopic images of common pigmented skin lesions. *Scientific Data*. 2018. Т. 5. С. 180161. URL: <https://doi.org/10.1038/sdata.2018.161> (дата звернення: 15.05.2026).

18. Hauser K. та ін. Explainable artificial intelligence in skin cancer recognition: A systematic review. *European Journal of Cancer*. 2022. Т. 167. С. 54–69. URL: <https://doi.org/10.1016/j.ejca.2022.02.025> (дата звернення: 15.05.2026).
19. Tjiu J.-W., Lu C.-F. Equity and Generalizability of Artificial Intelligence for Skin-Lesion Diagnosis Using Clinical, Dermoscopic, and Smartphone Images: A Systematic Review and Meta-Analysis. *Medicina*. 2025. Т. 61, № 12. С. 2186. URL: <https://doi.org/10.3390/medicina61122186> (дата звернення: 15.05.2026).
20. Vardasca R., Mendes J. G., Magalhaes C. Skin Cancer Image Classification Using Artificial Intelligence Strategies: A Systematic Review. *Journal of Imaging*. 2024. Т. 10, № 11. С. 265. URL: <https://doi.org/10.3390/jimaging10110265> (дата звернення: 15.05.2026).
21. Chanda T. та ін. Dermatologist-like explainable AI enhances trust and confidence in diagnosing melanoma. *Nature Communications*. 2024. Т. 15, № 1. С. 524. URL: <https://doi.org/10.1038/s41467-023-43095-4> (дата звернення: 15.05.2026).
22. Li M. та ін. Medical image analysis using deep learning algorithms. *Frontiers in Public Health*. 2023. Т. 11. С. 1273253. URL: <https://doi.org/10.3389/fpubh.2023.1273253> (дата звернення: 15.05.2026).
23. Alwakid G. та ін. Diagnosing Melanomas in Dermoscopy Images Using Deep Learning. *Diagnostics*. 2023. Т. 13, № 10. С. 1815. URL: <https://doi.org/10.3390/diagnostics13101815> (дата звернення: 18.05.2026).
24. Xu W., Fu Y.-L., Zhu D. ResNet and its application to medical image processing: Research progress and challenges. *Computer Methods and Programs in Biomedicine*. 2023. Т. 240. С. 107660. URL: <https://doi.org/10.1016/j.cmpb.2023.107660> (дата звернення: 27.05.2026).
25. Aldhyani T. H. H. та ін. Multi-Class Skin Lesion Classification Using a Lightweight Dynamic Kernel Deep-Learning-Based Convolutional Neural Network. *Diagnostics*. 2022. Т. 12, № 9. С. 2048. URL: <https://doi.org/10.3390/diagnostics12092048> (дата звернення: 18.05.2026).
26. Venkatachalam C., Venkatachalam S., Balakrishnan A. Enhanced skin cancer classification using modified efficientNetV2L with adaptive early stopping

mechanism. *Scientific Reports*. 2025. Т. 15, № 1. С. 38304. URL: <https://doi.org/10.1038/s41598-025-22228-3> (дата звернення: 15.05.2026).

27. Liu H.-I. та ін. Lightweight Deep Learning for Resource-Constrained Environments: A Survey. *ACM Computing Surveys*. 2024. Т. 56, № 10. С. 267. URL: <https://doi.org/10.1145/3657282> (дата звернення: 27.05.2026).

28. Himel G. M. S. та ін. Skin Cancer Segmentation and Classification Using Vision Transformer for Automatic Analysis in Dermatoscopy-Based Noninvasive Digital System. *International Journal of Biomedical Imaging*. 2024. Т. 2024. С. 3022192. URL: <https://doi.org/10.1155/2024/3022192> (дата звернення: 18.05.2026).

29. Khan S., Ali H., Shah Z. Identifying the role of vision transformer for skin cancer – A scoping review. *Frontiers in Artificial Intelligence*. 2023. Т. 6. С. 1202990. URL: <https://doi.org/10.3389/frai.2023.1202990> (дата звернення: 18.05.2026).

30. Iman M., Arabnia H. R., Rasheed K. A Review of Deep Transfer Learning and Recent Advancements. *Technologies*. 2023. Т. 11, № 2. С. 40. URL: <https://doi.org/10.3390/technologies11020040> (дата звернення: 15.05.2026).

31. Eliwa E. H. I. Enhancing Skin Cancer Diagnosis Through Fine-Tuning of Pretrained Models: A Two-Phase Transfer Learning Approach. *International Journal of Breast Cancer*. 2025. Т. 2025. С. 4362941. URL: <https://doi.org/10.1155/ijbc/4362941> (дата звернення: 15.05.2026).

32. Zeng W. Image data augmentation techniques based on deep learning: A survey. *Mathematical Biosciences and Engineering*. 2024. Т. 21, № 6. С. 6190–6224. URL: <https://doi.org/10.3934/mbe.2024272> (дата звернення: 15.05.2026).

33. Zhang X. та ін. DermViT: Diagnosis-Guided Vision Transformer for Robust and Efficient Skin Lesion Classification. *Bioengineering*. 2025. Т. 12, № 4. С. 421. URL: <https://doi.org/10.3390/bioengineering12040421> (дата звернення: 18.05.2026).

34. Nie Y. та ін. A Deep CNN Transformer Hybrid Model for Skin Lesion Classification of Dermoscopic Images Using Focal Loss. *Diagnostics*. 2022. Т. 13, № 1. С. 72. URL: <https://doi.org/10.3390/diagnostics13010072> (дата звернення: 15.05.2026).

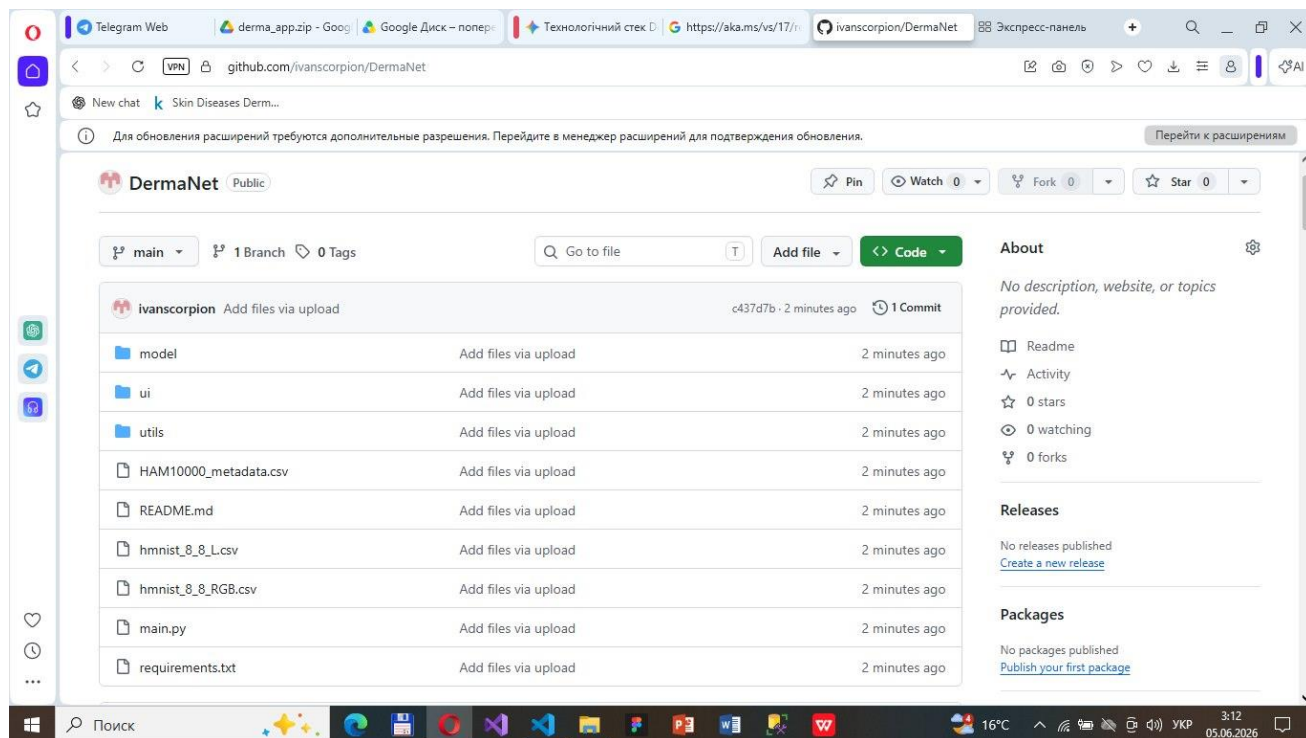
35. Thwin S. M., Park H.-S. Skin Lesion Classification Using a Deep Ensemble Model. *Applied Sciences*. 2024. Т. 14, № 13. С. 5599. URL: <https://doi.org/10.3390/app14135599> (дата звернення: 18.05.2026).
36. Shen S. та ін. A Low-Cost High-Performance Data Augmentation for Deep Learning-Based Skin Lesion Classification. *BME Frontiers*. 2022. Article ID 9765307. URL: <https://doi.org/10.34133/2022/9765307> (дата звернення: 05.06.2026).
37. Fiaz M. та ін. An explainable hybrid deep learning framework for precise skin lesion segmentation and multi-class classification. *Frontiers in Medicine*. 2025. Т. 12. С. 1681542. URL: <https://doi.org/10.3389/fmed.2025.1681542> (дата звернення: 05.06.2026).
38. SkinVision. URL: <https://www.skinvision.com> (дата звернення: 09.05.2026).
39. Model Dermatology. URL: <https://modelderm.com> (дата звернення: 09.05.2026).
40. DermaSensor. URL: <https://www.dermasensor.com> (дата звернення: 09.05.2026).
41. Skin Cancer MNIST: HAM10000. URL: <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000> (дата звернення: 15.05.2026).

ДОДАТКИ

Додаток А

Програмні коди

Вхідний код, використаний у дослідженні, доступний у відкритому репозиторії GitHub: <https://github.com/ivanscorpion/DermaNet>



Основні модулі системи

- `main.py` – головний файл застосунку; ініціалізує вікно Tkinter, встановлює заголовок «DermaNet» та запускає головне вікно.

- `requirements.txt` – перелік залежностей для відтворення середовища виконання.

Модулі моделі

- `model/factory.py` – фабрика моделей; залежно від обраного типу повертає класичну CNN або ResNet18 з перенесенням знань.

- `model/cnn_model.py` – порівняльний модуль: класичний пайплайн із екстрактором ~580 ознак зображення та гібридною конфігурацією Deep MLP / Random Forest; використовується для оцінки переваг основного CNN-підходу.

- `model/deep_cnn.py` – основний модуль системи DermaNet: CNN з трансферним навчанням на базі ResNet18 (PyTorch, ваги ImageNet); реалізує fine-

tuning layer4 та FC-класифікатора з 7 виходами, калібрацію ймовірностей та оптимізоване правило прийняття рішень.

- model/__init__.py – ініціалізаційний файл пакету model.

Модулі обробки даних

- utils/data_loader.py – завантаження та попередня обробка датасету HAM10000: читання зображень, масштабування, кодування міток, розбиття на train/val/test.

- utils/theme.py – кольорова палітра, шрифти та константи стилів застосунку DermaNet.

- utils/visualizer.py – побудова та збереження графіків у папку results/: криві навчання, матриця сплутування, ROC-криві, дашборд метрик.

- utils/__init__.py – ініціалізаційний файл пакету utils.

Модулі інтерфейсу користувача

- ui/main_window.py – головне вікно з вкладками; керує спільним станом між вкладками (модель, датасет, результати).

- ui/tab_train.py – вкладка навчання моделі: вибір датасету, параметрів, запуск тренування в окремому потоці, відображення прогресу.

- ui/tab_predict.py – вкладка діагностики: завантаження зображення шкірного ураження та отримання передбачення з ймовірностями класів.

- ui/tab_results.py – вкладка результатів: перегляд збережених графіків та метрик після навчання.

- ui/tab_about.py – інформаційна вкладка з описом системи та переліком класів захворювань HAM10000.

- ui/widgets.py – кастомні UI-компоненти: StatusBar, CardFrame, ModernButton, LogConsole, MetricBadge, ProgressSection.

- ui/__init__.py – ініціалізаційний файл пакету ui.

Збережені моделі

- dermanet_model.pkl – збережена класична модель у форматі joblib.

- dermanet_model_resnet.pt – збережені ваги CNN ResNet18 у форматі PyTorch.

- test_dermanet_model.pkl – тестова копія моделі для перевірки пайплайну передбачення.

- eval_results.pkl – збережені результати оцінювання моделі (метрики, передбачення, мітки).

Результати та графіки

- plots/00_summary_report.txt – текстовий звіт із зведеними метриками навчання та оцінювання.

- plots/01_training_curves.png – графіки динаміки loss та accuracy по епохах.

- plots/02_confusion_matrix.png – матриця сплутування на тестовій вибірці.

- plots/03_class_metrics.png – Precision, Recall та F1-score для кожного класу.

- plots/04_roc_curves.png – ROC-криві та значення AUC для кожного класу.

- plots/05_data_distribution.png – розподіл класів у датасеті.

- plots/06_prediction_analysis.png – аналіз передбачень: розподіл впевненості моделі.

- plots/07_metrics_dashboard.png – зведений дашборд основних метрик класифікації.

- plots/08_confidence_analysis.png – аналіз розподілу впевненості передбачень по класах.

Конфігурація та документація

- README.md – документація проєкту: опис системи, інструкція з встановлення та запуску.

- assets/ – зарезервована директорія для ресурсів застосунку (іконки, зображення тощо).

Додаток Б

Презентаційний матеріал

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

НЕЙРОМЕРЕЖЕВИЙ МЕТОД ІДЕНТИФІКАЦІЇ ДЕРМАТОЛОГІЧНИХ ЗАХВОРЮВАНЬ ЗА ФОТОЗОБРАЖЕННЯМИ



Виконав:

студент 4 курсу, група КН-22-1

Іван **СВЄЖЕНЦЕВ**



Керівник:

д.т.н., зав. кафедри КН

Олександр **БАРМАК**

Актуальність

Стрімкий розвиток методів глибокого навчання та комп'ютерного зору відкрив нові можливості для автоматизованої медичної діагностики, зокрема у сфері дерматології.

Рак шкіри є одним із найпоширеніших онкологічних захворювань у світі: щорічно реєструється понад 1,5 мільйона нових випадків, а п'ятирічна виживаність при метастатичній меланомі становить лише 15–22 %. Точність візуальної діагностики навіть досвідченими дерматологами не перевищує 65–80 %, що обумовлює суб'єктивність та варіативність клінічних рішень.

Ручна дерматоскопічна діагностика є трудомісткою, залежить від кваліфікації спеціаліста та недоступна у віддалених регіонах з обмеженими медичними ресурсами. Розробка нейромережевого методу автоматизованої ідентифікації дерматологічних захворювань за фотозображеннями є актуальним науково-практичним завданням у сфері медичних інформаційних технологій.

Мета і задачі кваліфікаційної роботи

Об'єкт дослідження – процес автоматизованої ідентифікації дерматологічних захворювань за фотозображеннями з використанням нейромережових методів.


Предмет дослідження – методи та засоби глибокого навчання, зокрема згорткові нейронні мережі з трансферним навчанням, для автоматизованої класифікації дерматоскопічних зображень.

Мета кваліфікаційної роботи бакалавра – підвищення точності та оперативності ідентифікації дерматологічних захворювань шляхом розробки нейромережового методу класифікації дерматоскопічних зображень на основі ResNet18 з трансферним навчанням та його практичної реалізації у вигляді настільного застосунку DermaNet.

Для досягнення мети необхідно було виконати такі задачі:

- виконати аналіз предметної області автоматизованої діагностики дерматологічних захворювань та існуючих підходів до їх вирішення;
- розробити нейромережовий метод ідентифікації дерматологічних захворювань за фотозображеннями на основі архітектури ResNet18 з трансферним навчанням;
- реалізувати програмний застосунок DermaNet для практичної апробації запропонованого методу;
- провести експериментальне дослідження та оцінити ефективність розробленого методу за стандартними діагностичними метриками.

Схема нейромережового методу ідентифікації дерматологічних захворювань за фотозображеннями



Інтерфейс програми

DermaNet

Навчання | Діагностика | Результати | Про систему

Діагностика ураження шкіри

Модель завантаження: CNN ResNet18 (transfer learning — рекомендовано) | Val Acc: 83.3%

Аналізувати

Результати діагностики

NV Низький

Меланоцитарний неvus
Melanocytic Nevus

Впевненість: 75.1%

Опис

Звичайна родимка — доброякісне скопчення меланоцитів у шкірі.

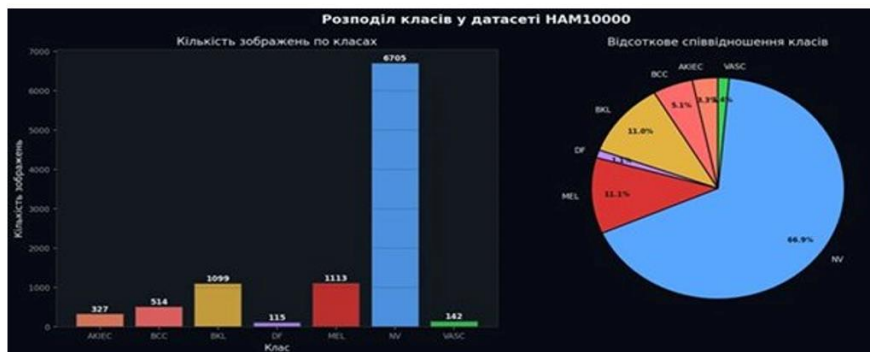
Рекомендоване лікування

Спостереження; видалення при зміні форми, кольору або розміру.

Розподіл ймовірностей


Клас	Ймовірність
NV	75.1%
VASC	7.1%
DF	6.0%
AKIEC	4.3%
BCC	3.5%
MEL	2.2%
BCI	1.6%

Навчальний набір даних HAM10000




Результати навчання

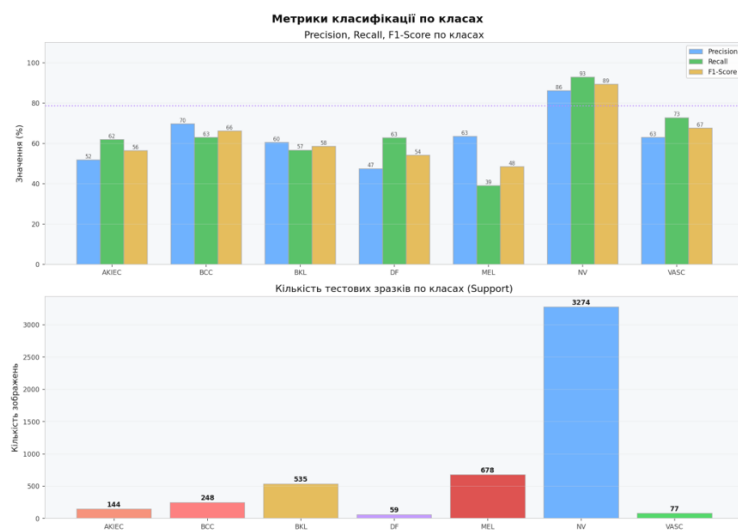
Криві навчання моделі



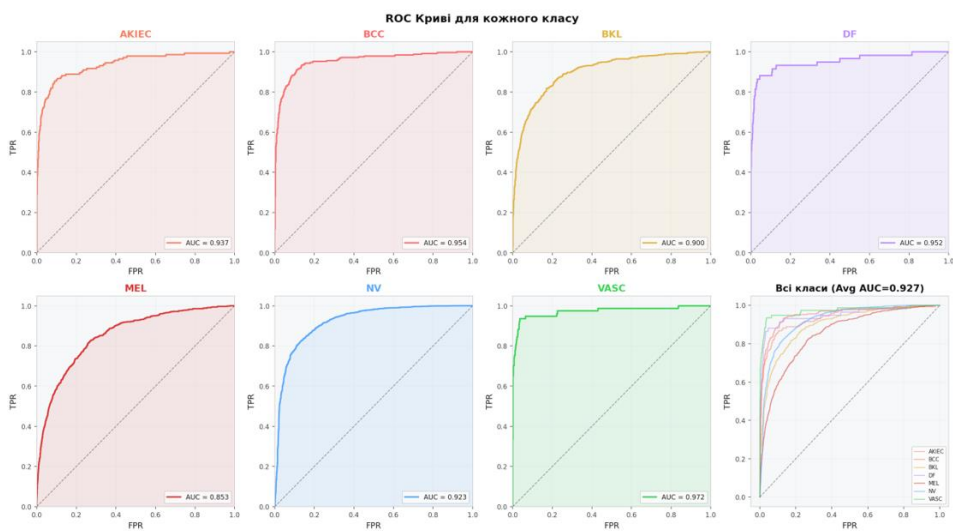
Результати навчання



Результати навчання

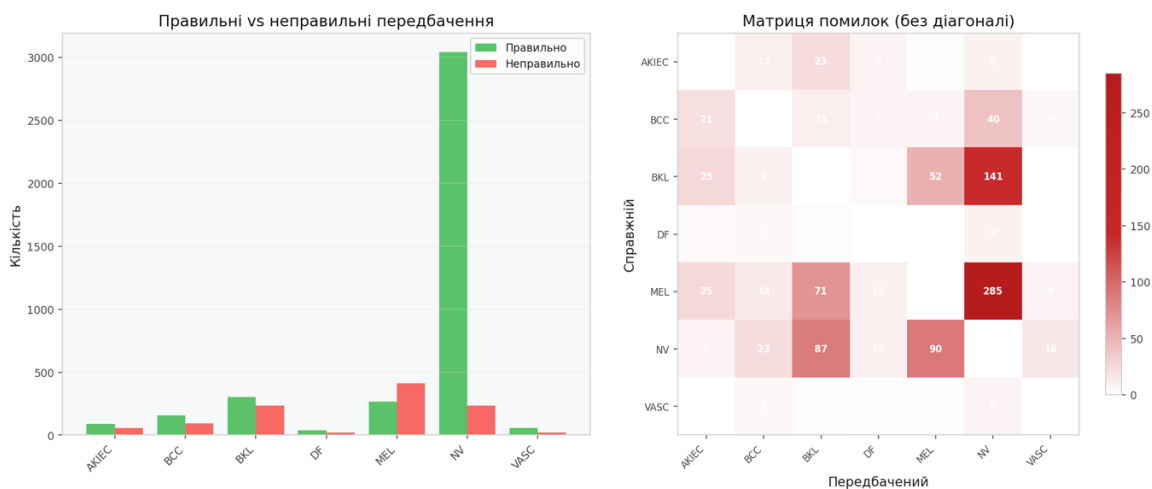


Результати навчання



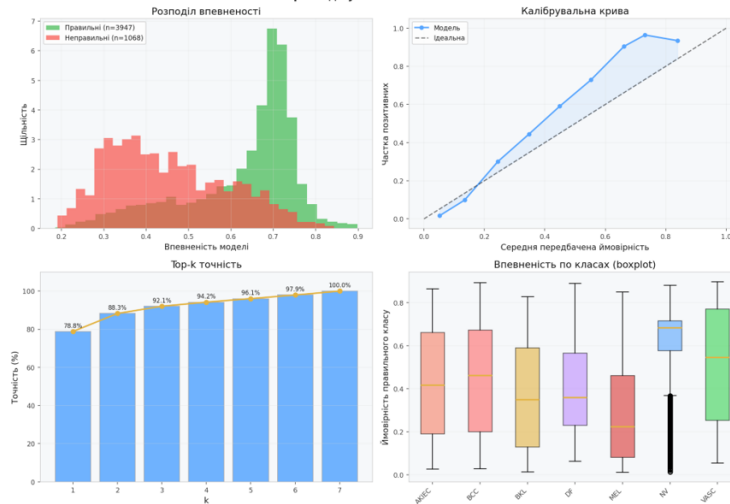
Результати навчання

Аналіз передбачень (правильні vs неправильні)



Результати навчання

Аналіз розподілу впевненості та помилок



Висновки

Досягнуто мети кваліфікаційної роботи бакалавра – підвищення точності та оперативності ідентифікації дерматологічних захворювань за фотозображеннями.

Розроблено неймережевий метод DermaNet та реалізовано настільний застосунок, що функціонує локально без передачі конфіденційних медичних даних у зовнішні сервіси та підтримує як CPU-режим, так і GPU-прискорення (CUDA).

Застосування архітектури ResNet18 з трансферним навчанням від ImageNet, fine-tuning останніх шарів, зваженої крос-ентропії та калібрації ймовірностей вирішило проблему дисбалансу класів (співвідношення 58:1), забезпечивши AUC-ROC = 91.37%

Порівняльний аналіз підтвердив конкурентоспроможність DermaNet відносно базових методів (Random Forest, SVM) при суттєво меншій апаратній вимогливості; Recall для класу меланоми становить 39.1%, що підтверджує доцільність позиціонування системи як інструменту підтримки клінічного рішення лікаря.

Визначено перспективи розвитку: перехід на архітектуру EfficientNet-B4, застосування Focal Loss та GAN-аугментації для рідкісних класів (DF, VASC), а також реалізація Grad-CAM візуалізації для підвищення пояснюваності рішень системи.

ДЯКУЮ ЗА УВАГУ!

16.06.26, 11:11

Anti-Plagiarism (http://ap.km.ua) v-16.718

Tue Jun 16 11:11:24 EEST 2026, Петровський Сергій Степанович, Хмельницький національний університет, ХНУ

Anti-Plagiarism (http://ap.km.ua) v-16.718**Максимальне співпадіння з одним документом 3.0%****Словники перевірки: UA, US, RU. Помилки в документах: 19%**

ID: 275516 Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Нейромережовий метод ідентифікації дерматологічних захворювань за фотозображеннями Додано в БД: 2026-06-16 Автора: Іван Свеженцев Керівники: Олександр БАРМАК Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	85355	762	3853 (5%)	55 (7%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

Протокол аналізу звіту подібності науковим керівником

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

Автор: Іван Свєженцев

Співавтор:

Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями

Науковий керівник: Олександр БАРМАК, д.т.н., проф.

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 6%

Коефіцієнт подібності 2: 1.92%

Мікропробіли: 0

Заміна букв: 42

Інтервали: 0

Білі знаки: 190

Дата створення звіту: 2026-06-16 07:56:46.0

Після аналізу Звіту подібності констатую наступне:

- Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.
- Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.
- Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедурам. Таким чином робота не приймається.

Обґрунтування:

2026-06-16

Пата

експерт

Петровський Р.Р. Ім

**РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК
ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ**

Назва кваліфікаційної роботи Нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями.

Автор студент групи КН-22-1 Свєжєнцеєв Іван

Освітня програма Комп'ютерні науки

Рівень вищої освіти перший (бакалаврський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: д.т.н., проф. зав.каф. комп'ютерних наук Олександр БАРМАК

На основі аналізу кваліфікаційної роботи на дотримання вимог академічної доброчесності (у т.ч. відсутності ознак академічного плагіату) з урахуванням результатів перевірки роботи спеціалізованим програмним засобом комісія зробила такий висновок:

№	Висновок	Позначка про відповідність
1	Ознаки академічного плагіату	
1.1	Запозичення, виявлені в роботі, є законними і не є академічним плагіатом (далі – зазначаються підстави віднесення запозичень до правомірних, якщо потрібно). Робота приймається до захисту.	<i>відповідає</i>
1.2	Виявлені запозичення не є академічним плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи (далі – зазначаються детальні та аргументовані підстави віднесення запозичень до правомірних). Робота приймається до захисту, але має бути відкоригована.	
1.3	Виявлені запозичення не є академічним плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота може бути допущена до захисту після того як буде відкоригована та доопрацьована і успішно пройде повторну перевірку на академічний плагіат.	
1.4	Робота містить навмисні текстові спотворення, передбачувані спроби укріття текстових запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	
2	Інші види порушень академічної доброчесності	<i>відсутні</i>

Підтвердження:

Запозичення, виявлені в роботі Івана Свєжєнцеєва, не є плагіатом, оскільки: запозичення розміщені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; до запозичень входять фрагменти, які не мають авторства і містять поширені конструкції та загальновідомі терміни, скорочення. Рівень подібності не перевищує допустимої межі. Таким чином, робота є законною та приймається до захисту.

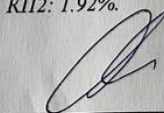
Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості:

- за системою Anti-Plagiarism: 3%;

- за системою StrikePlagiarism КП1: 6%, КП2: 1.92%.

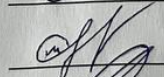
16.06.2025

Завідувач кафедри



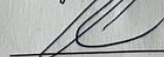
Олександр БАРМАК

Гарант освітньої програми



Олександр МАЗУРЕЦЬ

Керівник кваліфікаційної роботи



Олександр БАРМАК



ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
МОН УКРАЇНИ

Кафедра комп'ютерних наук



ВІДГУК НАУКОВОГО КЕРІВНИКА

на кваліфікаційну роботу бакалавра

студента *гр. КН-22-1 Свєженцева Івана Валерійовича*

за темою *Нейромержевий метод ідентифікації дерматологічних захворювань за фотозображенням*

1. Актуальність теми

Тема кваліфікаційної роботи є актуальною в галузі медичної інформатики та систем штучного інтелекту. Зростання захворюваності на онкологічні патології шкіри вимагає впровадження швидких та точних засобів ранньої діагностики. Точність автоматизованих нейромержевих методів аналізу дерматоскопічних зображень є важливим науково-прикладним завданням, що сприяє підвищенню ефективності первинного скринінгу захворювань.

2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки

Згідно зі стандартом, зокрема описом предметної області, об'єктами дослідження та діяльності є математичні, інформаційні та імітаційні моделі реальних явищ, об'єктів, систем і процесів, а також методи й технології для збирання, зберігання, обробки, передачі та застосування інформації. Об'єктом дослідження є процес автоматизованої ідентифікації дерматологічних захворювань за фотозображеннями, що передбачає обробку візуальних даних та побудову прогностичних моделей. Метою роботи є підвищення точності та оперативності ідентифікації дерматологічних захворювань. При вирішенні задачі використано методи глибокого навчання, зокрема згорткові нейронні мережі (CNN) з трансферним навчанням. Тому результати виконання кваліфікаційної роботи бакалавра відповідають стандарту бакалавра спеціальності 122 Комп'ютерні науки.

3. Професійні та особистісні якості бакалавра

За період підготовки кваліфікаційної роботи студент Свєженцев Іван проявив себе як відповідальний, організований та цілеспрямований здобувач вищої освіти, схильний до науково-дослідної діяльності. Він продемонстрував винятково сумлінне ставлення до виконання поставлених завдань, здатність до глибокого критичного аналізу предметної області, а також високу практичну компетентність у розробці та оптимізації програмних рішень на базі сучасних інформаційних технологій.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Результати, наведені у роботі, були отримані в результаті самостійної роботи студента, який виконав всі поставлені завдання без сторонньої допомоги.

5. Ступінь оволодіння методами дослідження

У процесі виконання кваліфікаційної роботи студент продемонстрував належний рівень професійних компетентностей, а також впевнене володіння інструментами, методами, технологіями та засобами, що використовуються в галузі комп'ютерних наук.

6. Повнота та якість розкриття теми роботи

Заявлена тема кваліфікаційної роботи розкрита в повному обсязі. У записі присутній детальний аналіз існуючих аналогів і моделей III, наведено строгу математичну формалізацію задачі багатокласової класифікації та представлено розроблений настільний програмний застосунок з інтерфейсом користувача. Проведені експерименти підтвердили високу ефективність запропонованого нейромережевого методу.

7. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

Матеріал кваліфікаційної роботи викладено у чіткій логічній послідовності. Текст написаний академічним стилем, висновки ґрунтуються на результатах експериментів і є аргументованими. Документ відповідає нормативним вимогам щодо оформлення кваліфікаційних робіт.

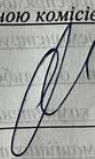
8. Можливість практичного застосування кваліфікаційної роботи бакалавра, окремих її частин

Розроблений метод і створений програмний застосунок мають високу практичну цінність. Вони можуть використовуватися лікарями-дерматологами як інструмент підтримки прийняття клінічних рішень для отримання альтернативної думки, а також лікарями загальної практики для первинного скринінгу уражень шкіри в умовах обмеженого доступу до спеціалістів.

9. Висновок про можливість допуску кваліфікаційної роботи бакалавра до захисту, на яку оцінку заслуговує робота

З огляду на високий рівень виконання, самостійність, актуальність результатів та повну відповідність вимогам, кваліфікаційна робота Свеженцева Івана допускається до захисту перед екзаменаційною комісією і заслуговує на оцінку – «відмінно».

Керівник


д.т.н., проф. зав. каф. КН Олександр БАРМАК



ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
МОН УКРАЇНИ



Кафедра комп'ютерних наук

РЕЦЕНЗІЯ

на кваліфікаційну роботу бакалавра

студента *гр. КН-22-1 Івана СВЄЖЕНЦЕВА*

за темою: Нейромережевий метод ідентифікації дерматологічних захворювань за фотозображеннями

1. Актуальність обраної теми

Тема кваліфікаційної роботи є актуальною в галузі медичної інформатики та систем штучного інтелекту. Зростання захворюваності на онкологічні патології шкіри вимагає впровадження швидких та точних засобів ранньої діагностики. Створення автоматизованих нейромережевих методів аналізу дерматоскопічних зображень є важливим науково-прикладним завданням, яке сприяє мінімізації суб'єктивних помилок під час візуального огляду і підвищує загальну ефективність первинного скринінгу.

2. Повнота розкриття мети та завдань роботи

Заявлена тема кваліфікаційної роботи розкрита в повному обсязі. У тексті кваліфікаційної роботи детально проаналізовано існуючі аналоги та моделі штучного інтелекту в медицині, наведено строгу математичну формалізацію задачі багатокласової класифікації та представлено розроблений настільний програмний застосунок з повноцінним інтерфейсом користувача.

3. Зміст кожного розділу роботи

У першому розділі автором ґрунтовно досліджено предметну область задачі ідентифікації дерматологічних захворювань та проведено критичний огляд існуючих систем комп'ютерного зору в медицині. Доцільно обґрунтовано вибір архітектури ResNet18. Другий розділ містить коректну математичну формалізацію задачі багатокласової класифікації. Заслуговує на увагу грамотний підхід здобувача до підготовки датасету HAM10000, зокрема використання методів аугментації та усунення дисбалансу класів при навчанні моделі. У третьому розділі послідовно описано функціонал розробленого застосунку DermaNet. Експериментальна частина виконана на високому рівні, результати тестування адекватно оцінені за допомогою загальноприйнятих метрик (Accuracy, F1-Score, ROC-AUC) та матриці помилок. Структура кваліфікаційної роботи є логічною, а зміст розділів повністю розкриває тему роботи.

4. Оцінка розробленого методу та його практична цінність

Розроблений метод та створене програмне забезпечення мають прикладну цінність. Вони можуть ефективно використовуватися лікарями-дерматологами як інструмент підтримки прийняття клінічних рішень, для отримання альтернативної думки, а також лікарями загальної практики для первинного скринінгу уражень шкіри в умовах обмеженого доступу до профільних спеціалістів.

5. Якість оформлення кваліфікаційної роботи бакалавра

Кваліфікаційна робота відповідає всім вимогам оформлення, чітко розкриває тему та мету дослідження. Структура логічна, викладення матеріалу послідовне, аргументоване та літературно грамотне.

6. Недоліки кваліфікаційної роботи бакалавра

До роботи студента Свєсенцева Івана є невелике зауваження: варто відзначити доцільність портування розробленого рішення на мобільні операційні системи. Поточна орієнтація програмного комплексу DermaNet на стаціонарні ПК децю обмежує автономність його застосування у практичній діяльності медичного персоналу. Створення мобільної модифікації застосунку значно розширило б прикладний потенціал запропонованого методу. Разом з тим, зазначене міркування є побажанням на майбутнє і жодним чином не впливає на загальну позитивну оцінку кваліфікаційної роботи.

7. Загальний висновок (допускається чи не допускається до захисту), та оцінка на яку заслуговує кваліфікаційна робота.

Враховуючи високий рівень виконання та відповідність усім вимогам, робота допускається до захисту. Рекомендована оцінка «відмінно».

Рецензент К.М.Р. Заремко, д.аб.кадр. АРІСТР *К.М.Р. Заремко*